



Title	機械学習を用いた波面計測・波面制御の高度化
Author(s)	西崎, 陽平
Citation	大阪大学, 2020, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/76643
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

機械学習を用いた
波面計測・波面制御の高度化

提出先 大阪大学大学院情報科学研究科
提出年月 **2020年1月**

西崎 陽平

発表論文リスト

原著論文

- [1] Y. Nishizaki, M. Valdivia, R. Horisaki, K. Kitaguchi, M. Saito, J. Tanida and E. Vera: “Deep learning wavefront sensing”, *Optics Express*, **27**, 1, pp. 240–251 (2019).
- [2] Y. Nishizaki, R. Horisaki, K. Kitaguchi, M. Saito and J. Tanida: “Analysis of non-iterative phase retrieval based on machine learning”, *Optical Review*, DOI: 10.1007/s10043-019-00574-8 (2020).
- [3] Y. Nishizaki, R. Horisaki, K. Kitaguchi, M. Saito and J. Tanida: “Improvement of wavefront control based on machine learning”, *Applied Optics* (2020). [in preparation]

国際会議

- [1] Y. Nishizaki, M. Valdivia, R. Horisaki, K. Kitaguchi, M. Saito, J. Tanida and E. Vera: “Deep learning wavefront sensing: Experimental demonstration with a point source”, *Information Photonics 2019 (IP2019)*, IP-6-06 (2019).

国内発表

- [1] 西崎 陽平 : “深層学習による波面計測”, 一般社団法人レーザー学会学術講演会第40回年次大会, S03-22a-VIII-03 (2020). [invited]

その他

- [1] 西崎 陽平, 齋藤 守, 北口 勝久, 谷田 純, 堀崎 遼一: “機械学習による波面センシング”, 大阪産業技術研究所 ORIST 技術シーズ・成果発表会 (2018).

目次

緒論	1
第1章 補償光学と機械学習	5
1.1 緒言	5
1.2 補償光学	5
1.3 波面計測	6
1.4 波面制御	7
1.5 機械学習を利用したコンピューショナルイメージング	11
1.6 本研究の意義と論文構成	13
1.7 結言	14
第2章 機械学習によるシングルショット波面計測	17
2.1 緒論	17
2.2 機械学習による波面計測	17
2.3 シングルショット波面計測	18
2.3.1 深層学習による波面計測原理	19
2.4 原理確認実験	20
2.4.1 点光源を用いた波面計測	23
2.4.2 2次元光源を用いた波面計測	27
2.5 考察	32
2.6 結論	33
第3章 深層学習を用いた非反復型位相回復と反復型位相回復の比較解析	37
3.1 緒論	37
3.2 位相回復	38
3.2.1 反復型回復	39
3.2.2 機械学習を用いた非反復型位相回復	40

3.3	数値実験による比較と考察	40
3.4	結論	46
第4章	機械学習による波面制御の高精度化	49
4.1	緒論	49
4.2	単一の可変型プログラムによる波面制御	51
4.3	可変型プログラムと固定型プログラムによる波面制御の高精度化	54
4.4	数値実験	57
4.4.1	1ビット振幅可変型プログラムと固定型プログラムによる波面制御 .	58
4.4.2	8ビット振幅可変型プログラムと固定型プログラムによる波面制御 .	58
4.4.3	1ビット位相可変型プログラムと固定型プログラムによる波面制御 .	58
4.4.4	8ビット位相可変型プログラムと固定型プログラムによる波面制御 .	59
4.4.5	考察	64
4.5	結論	66
総括		69
謝辞		73

緒論

人類は約 17,000 年前から、天体を観察していたとされている¹⁾。フランスのラスコー洞窟に描かれた動物壁画は、天体の星座を表し、天体现象を記録するためのものだったことが研究で明らかになっている。天体の動きと時間や四季との密接な結びつきを発見した古代の科学者らは、その後、Thales により日食の予言、Pythagoras 派の学者によって月や地球、太陽の相対的距離や大きさの概算手法を編み出しており、天体観測は古来から人類の興味の対象であった。

17 世紀に入り、C. M. Hall は屈折率の異なる 2 種類を組合せたアクロマートレンズの開発に成功し、課題であった色収差の解決に成功した。高コントラストな安定した像を観測できることから、月や惑星、太陽の研究が進んだ。一方、反射型望遠鏡は大型化が可能であることから解像力の向上に寄与する反面、構成部材である金属鏡の自重やその反射率の低さ、メンテナンス性の低さがボトルネックとなり直径は 184 cm にとどまっていた。18 世紀中期、化学プロセスの発展に伴う銀メッキ反射鏡の登場やアルミ蒸着メッキ、熱膨張率の低いガラスを使用するなどの技術革新を経て、これまでの直径を上回る 250 cm を超える大型反射望遠鏡が製作され、解像力の高い天体望遠鏡の開発が進んだ。しかし、地上からの観測における温度勾配や対流が要因である大気ゆらぎが屈折率の違いを生み出し解像力の低下を招いていた。

20 世紀後期には大気ゆらぎの影響を打破すべく、地球の衛星軌道上に天体宇宙望遠鏡を設けた米国のハッブル宇宙望遠鏡を代表とする宇宙望遠鏡の開発が進んだ²⁾。しかし、宇宙望遠鏡には運用コストの問題や、打ち上げロケットに搭載可能なサイズに制限されるなどの課題があった。

大気揺らぎの課題を解決する別の手段として、20 世紀中期に H. W. Babcock が補償光学の概念を提案した³⁾。補償光学は、計測系にて大気ゆらぎを定量的に測定し、制御系により大気ゆらぎをキャンセルするように波面変調する技術である。当時の技術では実現が困難であったが、その後の技術発展により、1977 年に J. W. Hardy らにより最初の補償光学系が開発され⁴⁾、1989 年には、G. Rousset らにより天体観測用補償光学系が開

発された⁵⁾。現在では、口径8~10 m以上の大型望遠鏡に標準搭載される基盤技術となっている。

2006年、補償光学に用いる参照光として人工的に打ち上げたレーザーガイド星による補償光学を日本のすばる望遠鏡により成功させた。ハワイで建設予定の次世代望遠鏡にもレーザーガイド星補償光学が使用される予定であり、より暗い天体の観測が可能になると期待されている。その解像力はハッブル宇宙望遠鏡の10倍以上、すばる望遠鏡の4倍以上になるとされている。しかし、補償光学では、揺動する大気や動体の観察に向け、数百~数千kHzのリアルタイム制御が求められるほか、観測対象の光が微弱なことが多いため、外乱やノイズに弱く、高いノイズ耐性も求められることが課題である。一般的に波面計測が可能な干渉計測手法では、振動耐性が低いため天体向け補償光学用途としては不向きである。したがって、簡易な光学系で構成される Shack-Hartmann 波面センサなどが利用されてきた⁶⁶⁾。一方、光学部品の検査などでは高精度計測が求められる干渉計が主に使用されるが、簡易な光学系であることからこのような分野においても Shack-Hartmann 波面センサは利用されている。

さらに天体観測から醸成された補償光学は、眼底検査⁶⁻¹⁰⁾や、顕微鏡¹¹⁾、バイオイメージング¹²⁻¹⁴⁾へ応用されている。1960年代、Smirnovが天文学とは独立に、眼の収差補正のアイデアを提案したとされる。1989年、P. Artalらがセグメントミラーを使用して、眼の低次収差を補正したことが眼底検査向け補償光学の先駆けとなっている¹⁵⁾。補償光学による水晶体等の歪みの補償は、鮮明な眼底画像を取得すること大きく寄与した。眼底画像は、目の疾患の他に、糖尿病、脳卒中、高血圧症、心血管疾患などの検査もできることが示唆されており、我々の生活の質を向上させる上で重要な技術となった¹⁶⁾。

生体に向けた補償光学の適用とその成功は、その後の医療分野や生物学分野を進展させることになる。天文学と共に発展した空間光変調技術により、生体試料を代表とする強散乱体を介したフォーカシングも可能にした。この応用は、光トラッピングや光マニピュレーションの技術深耕と共に、散乱体内部あるいは背部に補償光学で必要とされる参照光源を配することも可能にした。その結果、生体細胞に関する機能解明が進み神経科学が発展することになった。近年の成果では、E. Betzigらは構造化照明と補償光学を組み合わせることにより、生体内の生きた細胞の3次元映像取得に成功するなど、補償光学の重要性は増すばかりである^{14, 17)}。この成果は生体内部の観察に成功したほか細胞間の相互作用をリアルタイムに捕捉できることから、今後新たな生物学的発見や、神経系の機能に関する発見が期待される。

一方、情報科学分野においては、深層学習を代表とした機械学習が目覚ましい進化を遂げている。最初に機械学習に注目が集まったのは、1958年の単純パーセプトロンと呼ばれる重み付き入力モデルが発端であった¹⁸⁾。その後、D. E. Rumelhartらが単純パーセプトロンに対し、誤差逆伝播法と出力活性化関数に非線形連続関数であるシグモイド関数を適用することにより、多層ニューラルネットワークの表現力を向上させていった¹⁹⁾。しかし、シグモイド関数の利用では誤差逆伝播時に勾配消失問題が発生するため、X. GlorotらはReLU(正規化線形関数)を提案し、勾配消失問題を解決した。ReLU関数は、今日では最も標準的な出力活性化関数になっている^{20, 21)}。ソフトウェアの改善に加え、並列演算が可能なグラフィックカード向け素子の微細化と高集積化による演算ハードウェアの進歩も追い風となり、現在の第三次AIブームに至っている。

深層学習の応用先は自動運転や航空・宇宙における物体識別、物体検出、医療研究、産業の自動化、自動翻訳など多岐にわたる。近年では、光学分野においても、機械学習と融合したコンピューショナルイメージングが盛んになっており、散乱体越しの識別²²⁻²⁴⁾や再構成^{25, 26)}、壁からの反射散乱光による識別²⁷⁾、位相回復²⁸⁾、波面センシング^{29, 30)}、計算機合成ホログラフィ³¹⁾、顕微鏡³²⁾、微生物のスクリーニング³³⁾、フローサイトメトリ³⁴⁾などが挙げられる。これらはサポートベクターマシンなどの計算コストの低い機械学習から、深層学習のような計算コストの高い機械学習まで様々使用されており、これまで人間により行われてきた従来型設計・思想では到達できなかったであろう性能をもつシステムが研究されている。

本学位論文は、補償光学の要素技術である波面計測、波面制御の高度化を図るべく、機械学習と波面計測・波面制御を融合させた研究成果についてまとめたものである。既存手法におけるハードウェアあるいはソフトウェアによって受けていたダイナミックレンジや精度、演算速度、コスト、ノイズなどによる制約を、機械学習との融合を図った光学技術による実装によって緩和・打破し、機能や性能を向上させ、高精度、高速、低コスト、高いノイズ耐性などの特徴をもつ波面計測あるいは波面制御技術を実現する。

1章では、本研究を包括する補償光学と機械学習に関して解説し、本論文で取り扱う研究の意義と論文構成を述べる。

2章では、波面計測に深層学習を導入することにより、従来手法の設計自由度を大幅に拡大させる。その結果、これまで組み合わせることが困難であった簡単な光学変調と組み合わせることができ、反復演算することなく波面計測が実現できることを実験実証する。

3章では、位相回復に深層学習を導入した場合における従来手法との再構成精度、計算

速度について比較する。さらに、ノイズを加えた学習データセットによって訓練することにより、ノイズ耐性を向上できることを数値実験により明らかにする。

4章では、波面制御に機械学習を導入し、可変型ホログラム1つと固定型ホログラム1つを組み合わせて再生波面の精度向上を図る手法を示す。対象が所属するデータベースを基にした学習により、固定の変調光学素子を追加する。単一の可変型ホログラムでの再生に比べ、再生精度を向上できることを数値実験により明らかにする。

最後に本研究を統括し、今後の課題について述べる。

第 1 章

補償光学と機械学習

1.1 緒言

本章では、本研究の技術的な議論を進める上で重要となる基本的な概念を解説する。まず、補償光学について概説する。次に、補償光学の2大要素技術である波面計測と波面制御について説明する。さらに、近年発展が目覚ましい機械学習と光学を融合させたコンピュータシミュレーションについて説明する。

1.2 補償光学

補償光学は、Fig. 1.1 に示されるように計測系にて大気ゆらぎや生体細胞等の散乱媒質を透過する際の光のゆらぎを定量的に測定し、制御系により擾乱された波面をキャンセルするように変調する技術である。観測対象からの光波は光路中の大気ゆらぎや生体細胞等の散乱媒質により、波面が擾乱された状態で撮像系まで伝搬される。本来撮像されるべき光波へ変調するべく、参照光源からの光波を計測系である波面センサなどで観測する。この参照光源は天体分野では自然天体を利用する。または、レーザーを用いて高度 90 km にあるナトリウム層のナトリウム原子を発光させたナトリウムレーザーガイド星などが利用される。眼底検査等の医療分野では、中心波長 850 nm 程度の近赤外光による参照光源をターゲット付近へ配して計測される。計測された波面をキャンセルするように制御系である可変形鏡等を使用して、波面を変調する。天体分野では数百 Hz～数 kHz のリアルタイム制御が求められるため高速制御可能な反射型のデフォーミブルミラーが利用される。ただし、反射型の可変形鏡は高コスト、大規模、高消費電力、高計算コストが原因で、天体分野以外で利用される際の障害となっていた。そのため医療、工業分野では安価な液晶による波面制御が導入されている。

また、観測対象あるいは取得画像の光が微弱な場合における観測も課題である。信号が

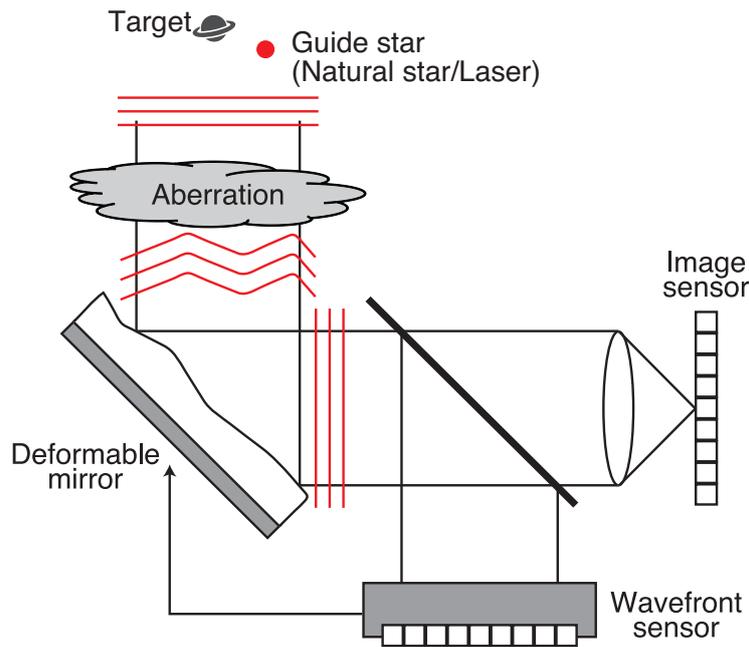


Fig. 1.1 Adaptive optics.

微弱な場合，外乱やノイズに弱くなり，計測精度を劣化させる．信号強度を増幅させるためにゲインを使用することが考えられるが，解析に不要なノイズまでも増幅させてしまうため，計測分野ではゲインが利用される機会は極めて少なく，改善が求められている．

1.3 波面計測

補償光学は波面計測と波面制御の 2 大要素技術により，構成されている．波面計測とは，位相波面を定量的に測定する技術である．ただし，イメージセンサは光波の強度にตอบสนองし，位相については取得することができない³⁵⁾．したがって，干渉現象を利用したアプローチ，回折現象を利用したアプローチ，あるいは光学素子とセンサを組合せた波面センサを利用したアプローチで波面計測に取り組みられてきた．

干渉計測

ホログラフィを代表とする干渉計測法では，マイケルソン干渉計やマッハ・ツェンダー干渉計などを利用して，コヒーレント光の干渉現象をもとに，対象の振幅と位相の両方を取得可能であることから広く普及している³⁶⁻³⁸⁾．応用先としてラベルフリーの生体医療イメージングや表面形状測定等へ利用されている³⁹⁻⁴⁴⁾．ただし，干渉計測法の欠点として，参照光を利用するために，光学系が複雑化してしまうこと

や、振動耐性が低いことが挙げられる。

回折イメージング

回折イメージングは回折光の強度画像を使用し、参照光なしで光波の振幅と位相を計測する手法である⁴⁵⁻⁴⁸。回折イメージングの欠点として、強度画像から位相を回復する逆問題を解くため、一般的には反復演算が必要な位相回復を適用する⁴⁹⁻⁵⁴。しかし、参照光が不要なことから、コンパクトな光学系を構成することができる。これまでに、結像光学素子の製造が困難であったX線領域にて、材料科学に応用されてきた^{55, 56}。近年では、可視領域においても、レンズレスイメージングやスペックル相関イメージングに対し位相回復技術が導入されている⁵⁷⁻⁶²。散乱を伴う信号取得のため、高いSN比で信号取得するためには、高強度な光源が必要である。しかし、高強度な光波照射は計測対象を損傷させてしまうことが課題である。

波面センサ

別の波面計測手法として、Fig. 1.2に示すように、イメージセンサの前方にマイクロレンズアレイを設置したシャックハルトマン波面センサや、四角錐プリズムを設置したピラミッド波面センサ、あるいは、主レンズとレンズアレイを設置したプレノプティック波面センサが提案されてきた⁶³⁻⁶⁸。解析的に扱いやすい光学素子による波面変調を利用していることから、天体観測だけでなく産業利用も進んでいる。しかし、これら波面センサは特殊な素子を利用するため、コスト面やアライメント、ダイナミックレンジ、線形性、複数撮影、あるいは計算コストなどの点で制約を受ける。

1.4 波面制御

補償光学のもう一つの要素技術である波面制御は、光波を任意波面へ変調する技術である。光波は、空間光変調器 (SLM : Spatial light modulator) によって、複素振幅のうち位相あるいは振幅のどちらか一方を制御することが可能である。波面制御方式として、液晶、デジタルマイクロミラーデバイス (DMD : Digital micromirror device)、積層ピエゾアクチュエータ型デフォーマブルミラー、バイモルフ型デフォーマブルミラーを利用して光波を制御する⁶⁹⁻⁷⁴。研究段階ではあるが磁気光学効果を利用して光波を制御する方式も検討されている⁷⁵。

液晶による変調

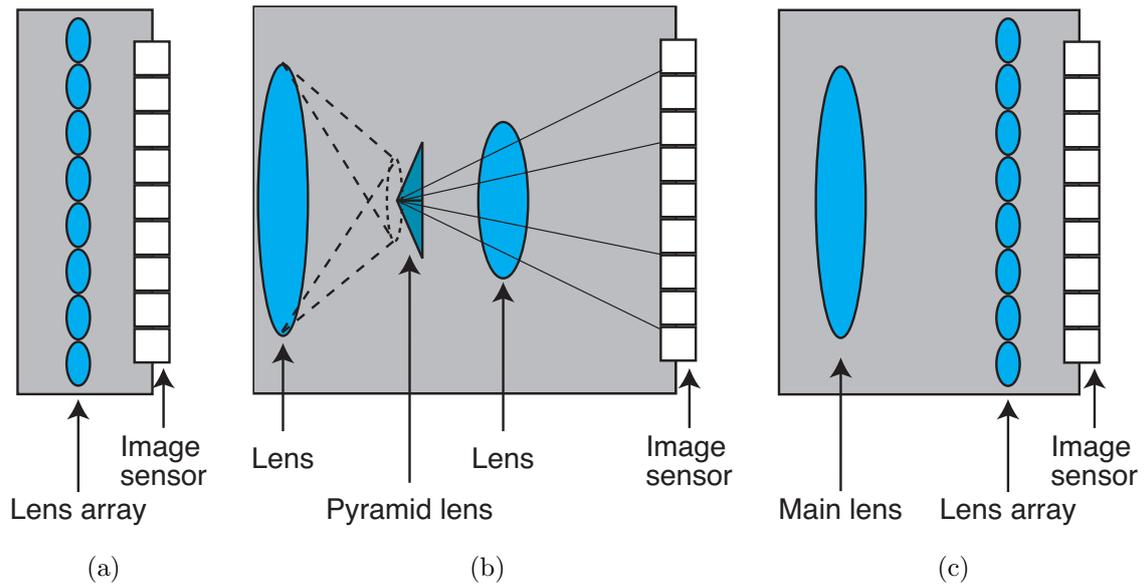


Fig. 1.2 Wavefront sensors. (a) Shack-Hartmann, (b) pyramid and (c) plenoptic.

液晶による変調は，Fig. 1.3 に示すように印加電圧量を変化させることにより液晶の配光方向を任意に制御できる結果，位相差を自在に制御することが可能となる．液晶の応答速度がボトルネックとなり，数 100 Hz 程度の制御速度に制限される．

DMD による変調

DMD による変調は，Fig. 1.4 に示すように微小なミラー群を敷き詰めたデバイスによる駆動方式である．微小なミラーは独立して制御され，印加される電圧により光波の反射方向を 2 方向へ切り替え，光の振幅の On と Off を制御することができる．民生用途としてはプロジェクタなどへ広く普及されている．微小ミラー単独かつバイナリ変調であれば $10 \mu\text{s}$ 程度で高速制御が可能である．高い反射率のミラーを使用していることから，高出力光波の変調が可能とされている．しかし，強度積算による階調表現のため，コヒーレント光を使用する場合は 1 ビット (2 階調) での振幅変調に限定される．

ピエゾアクチュエータを利用したデフォーマブルミラーによる変調

積層ピエゾアクチュエータ型デフォーマブルミラーは，Fig. 1.5 (a) に示すようにピエゾと呼ばれる印加電圧により長さが変化する素子により，鏡の形状の変化を与えている．ピエゾ素子を光軸方向に積層して使用することにより，変位量を大きくし

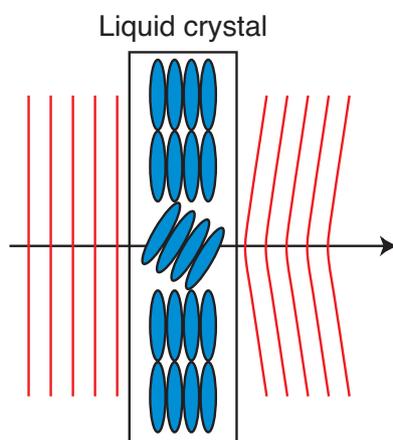


Fig. 1.3 Wavefront control based on liquid crystal.

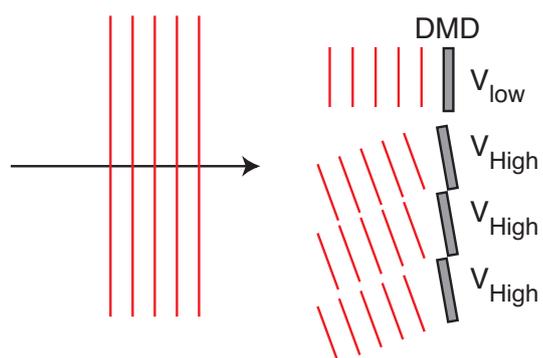


Fig. 1.4 Wavefront control based on DMD.

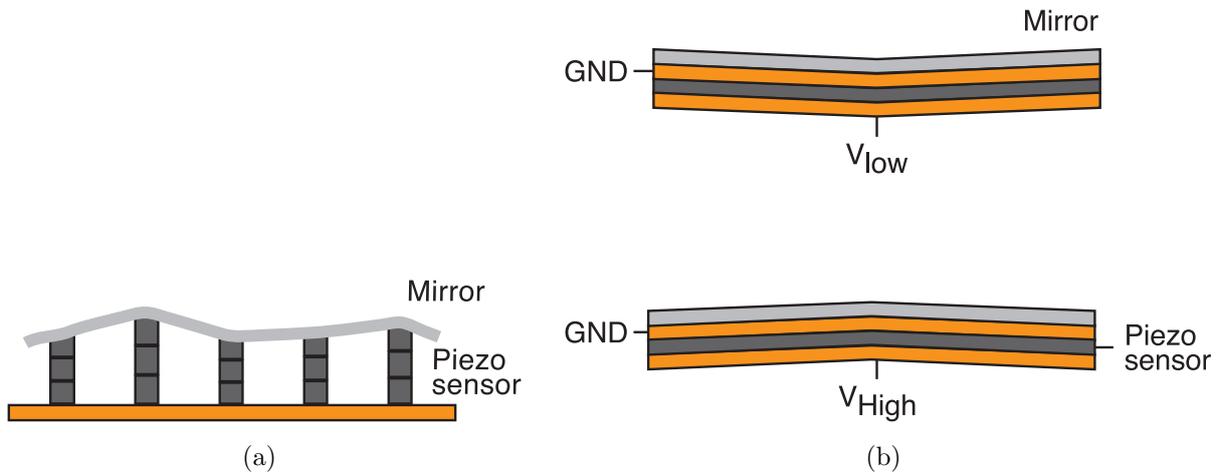


Fig. 1.5 Wavefront control based on Piezo actuators. (a) Stacked piezo-actuator and (b) bimorph.

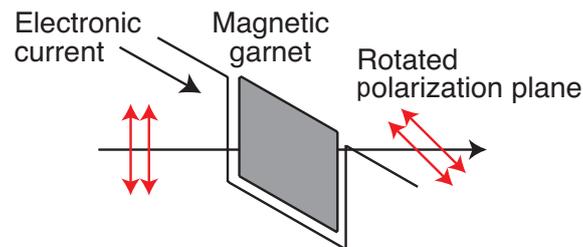


Fig. 1.6 Wavefront control based on magneto-optical effect.

ている。一方、バイモルフ型デフォーマブルミラーは、Fig. 1.5 (b) に示すように光軸に対して垂直方向にピエゾ素子の長さ変化を与えるようにして、鏡の形状変化を与えている。両方式共にピエゾアクチュエータの変形量によって変調量が制限される。

磁気光学効果による変調

近年では、Fig. 1.6 に示すように磁気光学効果を利用した新しい空間光変調器も開発されている⁷⁵⁾。磁気光学効果は磁場をかけた物質の透過光や反射光の偏光状態を変化させる現象である。これを利用した磁気光学空間光変調器ではDMDよりも高速な数 10 ns 程度で高速制御が可能とされることから、ホログラフィックメモリや 3次元ディスプレイなどへの応用に向けた研究がなされているところである。

ただし、これら例示した空間光変調器は振幅あるいは位相のどちらか一方しか制御出来

ないため、所望の光波場を高精度に再生することはできない。そのため、空間光変調器を複数利用した手法が提案されている^{76, 77)}。2003年、S. Borgsmüllerらは、光軸に沿って複数の回折光学素子を配置し、精度向上に成功した。2018年には、H. Wangらは複数の空間光変調器と、レンズあるいは凹面鏡を組み合わせることにより、S. Borgsmüllerらの光学系と同様な表現力の高い変調を実現した⁷⁷⁾。しかし複数の空間光変調器の利用に伴い、光学系が高コスト化することが課題となる。

ホログラムの再生性能を向上させる、あるいは機能拡張させる別の手段として、ランダムピンホール、ディフューザ、回折光学素子 (DOE : Diffractive optical element) を挿入する研究がなされている⁷⁸⁻⁸³⁾。M. Zhengらは空間光変調器に生成したホログラムをDOEで複製し、マルチ光トラッピングを成功させた⁷⁸⁾。渋川らは、空間光変調器の後方にディフューザを設置した光学系を想定してホログラムを設計し、ホログラフィックメモリへの応用研究をおこなっている⁷⁹⁾。J. Parkらは、空間光変調器とランダムピンホールアレイと組合せて使用することによりホログラフィックディスプレイの視野角を拡大させた⁸⁰⁾。W. Songらは、ピンホールアレイと組合せることにより、光線追跡型3Dディスプレイの視野拡大を達成させている⁸¹⁾。さらに、H. S. Yuらは、空間光変調器とディフューザにより動的な3次元ディスプレイの開発に成功した⁸²⁾。一方、X. Linらは、複数のランダム位相変調層と機械学習を組合せ、光学分類器を発明した⁸³⁾。

1.5 機械学習を利用したコンピューショナルイメージング

情報科学と光学の融合分野はコンピューショナルイメージングと呼ばれ、これまで人間により行われてきた従来型設計・思想では到達できなかったであろう性能をもつシステムが研究されてきた。中でも、近年の機械学習アーキテクチャの進展と演算ハードウェアの進歩により、機械学習と光学分野の融合研究についても様々な応用が検討されてきている。本節では、機械学習を利用したコンピューショナルイメージングの研究例を4つのカテゴリで整理する⁸⁴⁾。

超解像

2014年、C. Dongらは機械学習を用いたアップサンプリングによる超解像を実現した^{85, 86)}。低解像度と高解像度の画像セットから超解像深層学習ネットワークを構築し、従来手法よりも優れた結果を示している。本手法では、非反復で超解像の機能実装が可能となった。2017年、M. Mardaniらはカスケード型のネットワークにおいても超解像可能であることを示した⁸⁷⁾。また、C. J. Schulerらは2層の隠れ層を

もつパーセプトロンネットワークを用いて静的ブラーを解決した⁸⁸⁾。その2年後には、畳込みニューラルネットワークを用いて対象の動作方向を予測させ、動的ブラーを解決するに至った⁸⁹⁾。一方、顕微鏡における超解像適用事例として、Y. Rivensonらが挙げた研究がある³²⁾。これまでのブラインドデコンボリューションによる反復処理でなく、深層学習の追加により非反復でブラーの除去やアップサンプリングの超解像が可能であることを実証した成果である。

定量位相計測およびレンズレスイメージング

2017年、A. Sinhaらはレンズレス回折イメージングの位相回復に対し機械学習を導入した²⁸⁾。機械学習が、非線形問題である位相回復に対する解析手法として機能することを発見した。また、反復演算が必要であった位相回復は、深層学習を使用することにより反復不要となり高速位相推定が可能となった。同年、Y. Rivensonらはバイオイメージング分野におけるデジタルホログラフィに対し物理学の知見も採用した機械学習を導入した⁹⁰⁾。取得された子宮頸がん細胞、乳房細胞組織あるいは血液塗抹等を記録した複数枚ホログラムを学習画像とし、正解画像と紐付けた。畳込みニューラルネットワークにより学習された後は、単一のホログラムを入力するだけで従来手法と同程度の再構成精度の画像を高速に得ることに成功している。

低照度下におけるイメージング

2017年、T. Remezらは、深層学習を利用し、低照度下におけるデノイズングに成功した⁹¹⁾。彼らの研究では、畳込みニューラルネットワークによりノイズを学習し、画像のデノイズングをおこなった。さらに、画像分類に特化したネットワークを利用してことから画像分類も同時に導くことにより、さらに高度なデノイザになることを示した。A. Goyらは単一光子レベルの低照度な強度画像からの位相回復に、物理学の知見もネットワークに組み込んだ深層学習が有用であることを示した⁹²⁾。2017年、M. Lyuらは単一フォトダイオードによるイメージングであるゴーストイメージングへも深層学習を導入した⁹³⁾。深層学習の追加導入により、従来手法だけでは再構成できなかった低照度画像からでもゴーストイメージングが可能になることを示した。また、圧縮センシングも適用し、低照度かつサンプリング比5%でも再構成が可能であることを示した。

散乱環境下におけるイメージング

これまで、散乱応答関数の導出あるいはメモリ効果を利用したスペックル相関法に

より、強散乱領域での散乱イメージングが実現されてきた。第三の手法として、堀崎らは強散乱体を介して得られた画像に対し、サポートベクター回帰による学習を適用しその性能を実証した²⁵⁾。この手法に続き、弱散乱体あるいは強散乱体を通した散乱イメージングに対し畳込みニューラルネットワークが導入され、その再構成精度はさらに高まることになった^{26, 94)}。散乱イメージングの応用は広く、視野外からの情報、すなわち壁などからの散乱情報を含んだ反射光をも利用が可能とされている。この情報を利用し、散乱イメージングは行動分類²⁷⁾や1光子シングルピクセルによる人物分類と3次元位置測定までも成功に導いている⁹⁵⁾。

1.6 本研究の意義と論文構成

本論文の構成を Fig. 1.7 に示す。本論文では、波面計測、波面制御の高度化を図るべく、機械学習と波面計測・波面制御を融合させる。光学技術に機械学習を融合することにより、物理プロセスに基づいて人間が設計した従来技術・従来手法を凌駕する光学技術を提案する。本論文の研究項目は次の三つに分けられる。

2章では、1.5節の定量位相計測手法に所属する波面計測技術の高速化、簡便化、低コスト化ならびに波面センサの一般化を図る。波面センサに対し、機械学習を導入することにより、設計自由度を拡張させる。このコンセプトにより、従来必要であったプレコンディショニングのための光学素子を挿入しなくても、過剰露光、デフォーカス、散乱板挿入などの簡便なプレコンディショニング手法を使用することにより波面計測が実現できるようになる。また、反復演算することなく波面の推定が可能になることから高速計測が可能となる。本手法では、簡便なプレコンディショニングによって得られた単一強度画像から、非反復で波面センシングが実現されることを実験実証する。本技術の適用により、低コストな波面センサの開発・普及に寄与できるため、製造業における検査コスト低減、品質向上などが期待される。

3章では、1.5節の低照度下におけるイメージングに所属する位相回復技術において、深層学習を導入した場合における再構成精度、計算速度について従来手法と比較する。さらに、ノイズ耐性の向上を図るべく、機械学習のネットワーク深さを変えた学習や、ノイズを加えた訓練画像による学習により数値実験を実施した。本手法の適用により、低侵襲、高ロバストである位相回復が実現可能になり、非破壊検査やライブイメージングへの適用が期待される。

4章では、1.5節の散乱環境下におけるイメージング技術に所属する計算機合成ホログ

ラム技術の高精度化，低コスト化を図る．1つの空間光変調器と1つの最適化設計された回折光学素子による再生により，再生精度を向上させる．回折光学素子には，再生対象が所属する集合を含むデータベースを用い，設計光波と目標とする再生光波の誤差を最小化するように学習を行う．提案手法の実証のため，数値実験をおこなった．本手法の適用により，コストパフォーマンスに優れた波面制御へ寄与し，3Dディスプレイや光ピンセット等に応用することによって，技術の普及拡大，低コスト化が期待される．

1.7 結言

本章では，本研究全体に渡る基本的な概念について説明した．

1.2節では，補償光学の利用形態と，応用について説明した．1.3節では，主な波面計測手法について説明した．1.4節では，主な波面制御方法について説明した．1.5節では，機械学習と光学を融合したコンピュータシミュレーションの応用例について説明した．1.6節では，本論文の意義と構成を図と共にまとめた．本研究では，機械学習と光学系を融合したフレームワークを通じて，補償光学の要素技術である波面計測と波面制御の高度化を光学実験あるいは数値実験により実証する．

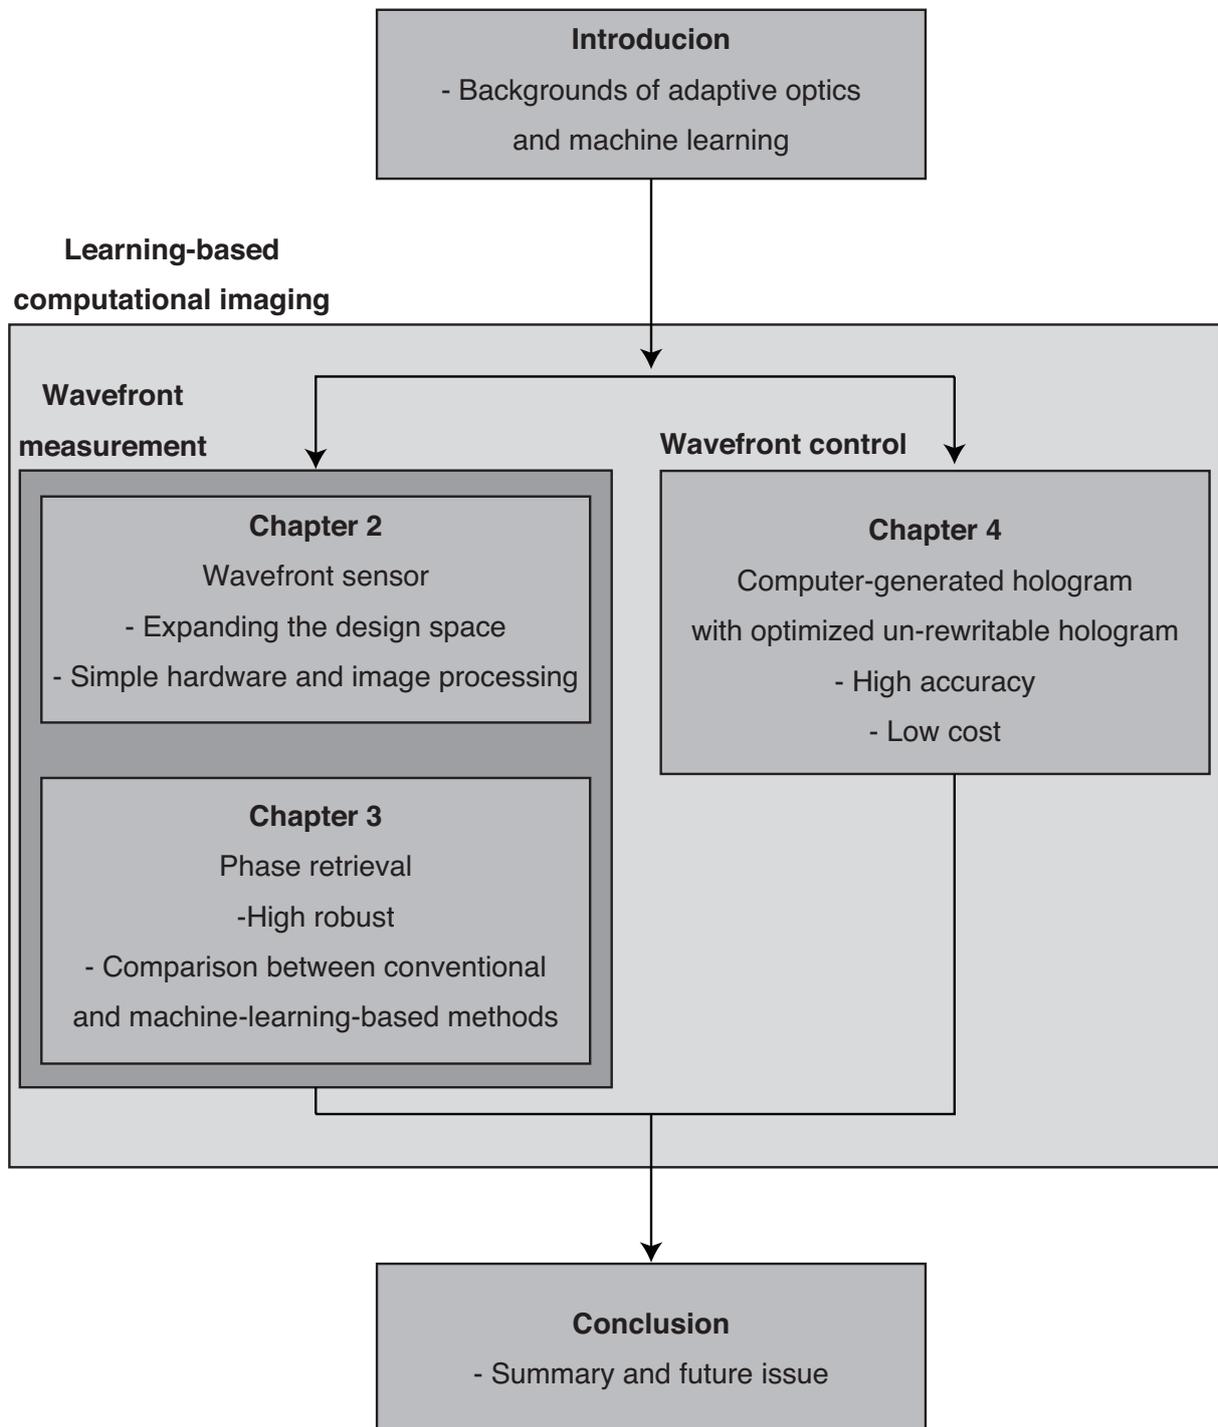


Fig. 1.7 Structure of this dissertation.

第 2 章

機械学習によるシングルショット波面計測

2.1 緒論

波面計測は光波の波面収差測定手法としてバイオイメージングや天文学にむけた補償光学のために広く使用されてきた^{66, 96, 97)}。これまでにマイクロレンズアレイを利用したシャックハルトマン波面センサや、四角錐プリズムを利用したピラミッド波面センサ、あるいは、主レンズとレンズアレイを利用したプレノプティック波面センサを利用した波面計測がおこなわれてきた⁶³⁻⁶⁸⁾。これら例示した手法は光学素子コスト、アライメント、ダイナミックレンジ、線形性、複数撮影、波面再構成計算コストの点などから、程度の違いはあるが、多くの制約を受ける⁹⁸⁾。他手法としてランダム変調を利用した波面計測手法が提案されているが、波面収差の低周波成分が支配的であることを前提条件としていることや反復演算が必要であることが課題となっている⁹⁹⁻¹⁰²⁾。

本章では、波面センサに深層学習を導入し、従来手法の設計自由度を拡張させる技術について述べる。2.2 節では、機械学習を導入した最近の波面計測手法とその課題について述べる。2.3 節では、波面センサに深層学習を導入する。また、波面計測の基本原理及び設計自由度拡張の役割を担う新規プリコンディショニングについて述べる。2.4 節では、提案手法の実証のための光学実験をおこなう。更に、従来からある点光源を対象としたシステムだけではなく、2次元光源を利用した波面計測の実証をおこなう。2.5 節では、実験結果に関する考察を示す。

2.2 機械学習による波面計測

これまでも機械学習と組合せた波面計測手法が提案されている^{103, 104)}。位相ダイバーシティ波面センサによる波面推定では、一般的な回帰ニューラルネットワークで計算されるが、複数のイメージセンサーが必要とされる¹⁰³⁾。H. Guo らは、逆伝播で訓練された

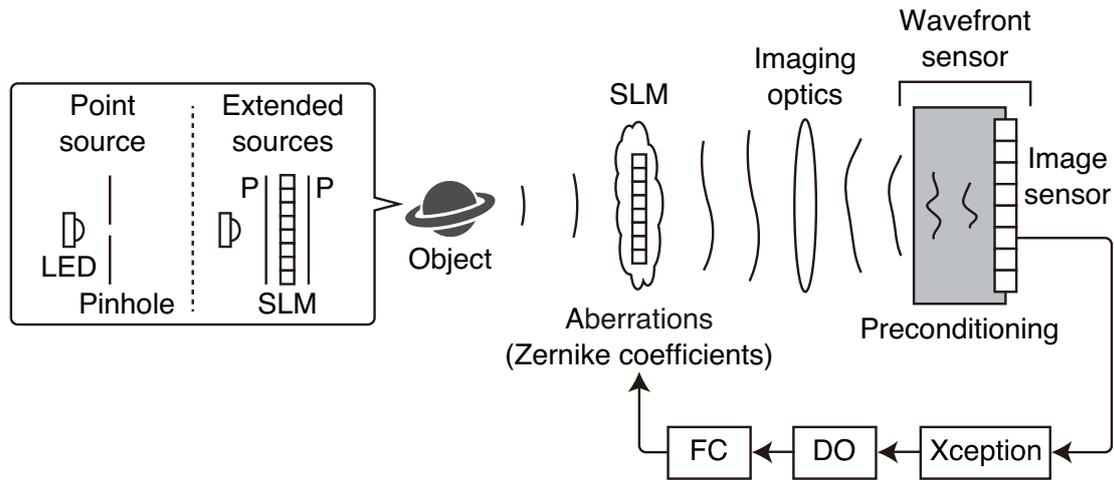


Fig. 2.1 Schematic diagram of the deep learning wavefront sensor (DLWFS). LED : light emitting diode. P : Polarizer. SLM : Spatial light modulator. Xception : A convolutional neural network. DO : Dropout layer. FC : Fully connected layer.

多層ニューラルネットワークを使用して、シャックハルトマン波面センサの波面再構成の計算要件を緩和することにより、ゼルニケ係数を直接推定した¹⁰⁴⁾。最近では、畳み込みニューラルネットワークによる学習により、点像分布関数 (PSF : Point spread function) 測定からゼルニケ係数を推定するための初期値推定がなされているが、依然として反復処理が必要であった²⁹⁾。このように波面センサは、古くからハード面、ソフト面からのアプローチにより波面推定がなされてなされてきたが、補償光学における動的波面のリアルタイム計測の実現のため、シンプルかつ解析的に扱いやすいレンズアレイや、プリズムあるいは結像レンズにより波面変換し計測されてきた。これら波面変換機能をもつ光学素子あるいは機能を本論文ではプリコンディショニングと呼ぶ。しかし、従来型プリコンディショニングは、その強度測定により波面計測が実現されている一方、波面計測システム全体としては機能制限の要因となっていた。

2.3 シングルショット波面計測

ここで提案する手法では、波面計測と機械学習のひとつであるディープラーニングを組み合わせることにより、現在の波面センサの設計自由度を大幅に改善させることを目的としている。本手法による波面センサを、本研究内ではディープラーニング波面センサ (DLWFS : Deep learning wavefront sensor) と呼ぶ。本手法の概要を Fig. 2.1 に示す。波面センサにより取得された単一強度画像から機械学習によりゼルニケ係数を直接推定

し、波面計測を実現させる。本研究では、機械学習に Xception と呼ばれる畳込みニューラルネットワークを使用した¹⁰⁵⁾。Xception は 2017 年に提案された深層学習ネットワークであり、近年提案されている他のネットワークと比較し、高い汎化能力でありながら、学習コストが低い特徴をもつ効率的なネットワークである。ここでは、Xception を用い、Fig. 2.1 に示すように、ドロップアウト層と全結合層を追加することにより、ゼルニケ係数が推定可能な回帰ネットワークを設計した。設計されたネットワークにて学習を行うことにより、学習終了後は単一強度画像を入力するだけで、反復演算することなくゼルニケ係数を推定することが可能となる。

2.3.1 深層学習による波面計測原理

Fig. 2.1 に示すように、点光源あるいは 2 次元光源からの光波は、温度勾配による屈折率変化や流動が原因で大気擾乱された状態でイメージングされ、

$$\mathbf{I} = \mathbf{h} \otimes \mathbf{f}, \quad (2.1)$$

$$\mathbf{h} = |\mathcal{F}[\mathbf{w}]|^2, \quad (2.2)$$

と表すことができる³⁵⁾。ここで、 \mathbf{I} は波面擾乱後の観測強度画像、 \mathbf{h} は点像分布関数、 \mathbf{f} は元信号、 \otimes は畳込み演算子、 $\mathcal{F}[\bullet]$ はフーリエ変換演算子、 \mathbf{w} は擾乱位相波面である。擾乱される位相波面 \mathbf{w} はゼルニケ多項式の各モードの足し合わせで表現できることが知られており、

$$\mathbf{w} = \sum_{i=1}^{\infty} s_i \mathbf{Z}_i(r, \theta), \quad (2.3)$$

と表される¹⁰⁶⁾。ここで \mathbf{Z}_i は i 次ゼルニケ多項式、 s_i は i 次ゼルニケ係数、 r は瞳面の極座標系における半径、 θ は瞳面の極座標系における方位角である。本研究では、取得される単一強度画像 \mathbf{I} から式 (2.3) の s_i を推定を目指しているが、イメージセンサの限られたダイナミックレンジが推定を困難にさせている。これは、波面計測に限った課題でなくコンピュータシミュレーション分野において課題となっている¹⁰⁷⁾。この課題は、収差が僅かに存在するときに特に顕在化し、PSF のエネルギーのほとんどが中央ピクセルに集中してしまう。

この課題を打破するべく、Fig. 2.1 に示すように、DLWFS に入射する光波に対して収差強調の役割を果たすプリコンディショニング \mathcal{P} を導入する。これにより、式 (2.1) は、

$$\mathbf{I}_p = \mathcal{P}[\mathbf{h} \otimes \mathbf{f}], \quad (2.4)$$

と書き改めることができる。ここで、 I_p はプリコンディショニングを利用して撮影された強度画像である。本手法では、機械学習と波面計測を組み合わせたことにより、レンズアレイや四角錐プリズム等の従来型プリコンディショニングに限定されない柔軟なプリコンディショニングを設計することが可能となる。提案するプリコンディショニングの一部を Fig. 2.2 に示す。過剰露光，デフォーカス，散乱板挿入などの特別な設計を必要としない簡便なプリコンディショニングが使用可能であり，収差を容易に強調させることが可能となる。DLWFS では，これら新規プリコンディショニング単体，従来型プリコンディショニング単体，新規プリコンディショニングを複数組合せた形式，従来型プリコンディショニングを複数組合せた形式，あるいは新規プリコンディショニングと従来型プリコンディショニングとの融合型でも使用することが可能であり，これまでの波面センサの設計自由度を大幅に改善させることができる。

式 (2.4) の強度画像から，式 (2.3) の s_i を推定することは，非線形問題であり，特に Fig. 2.2 (b) のような過剰露光による特徴量強調がなされる場合は推定が困難である。これら逆問題に対し，近年，機械学習を使用した非線形アプローチによる解法が注目を浴びている^{22, 29, 103, 104}。本手法では，実験を通じ，機械学習によって直接ゼルニケ係数を推定し，反復演算なしで波面計測が可能であることを示し，波面センサの設計自由度が拡張可能されることを実証する。

2.4 原理確認実験

一般的な波面計測システムでは，点光源が使用される。点光源は，光学システムあるいは擾乱媒体から十分遠くに配置され，平面波が擾乱媒体へ入射される。補償光学における波面基準光源のため，実際にある自然な天体をガイド星として利用し波面計測を行うことが，一般的な使用方法である。一方，次世代大型望遠鏡に向けた高度補償光学技術では，自然な天体を利用する点光源ではなく，人工的に生成されたレーザーガイド星が必要となっている。ただし，現在の波面計測システムでは点光源以外の形状を利用した設計とはなっていない¹⁰⁸。本提案手法では，従来型の点光源および2次元光源を使用し，提案する DLWFS の実験実証をおこなった。

提案手法との比較のため，プリコンディショニングを使用しないインフォーカスセットアップで取得された強度画像を利用した波面計測をベースラインとした。次に，過剰露光，デフォーカス，散乱板挿入のプリコンディショニングを使用した DLWFS の実証を行う。透過型空間光変調器 (SLM : Spatial light modulator) を使用して，乱流などを模した

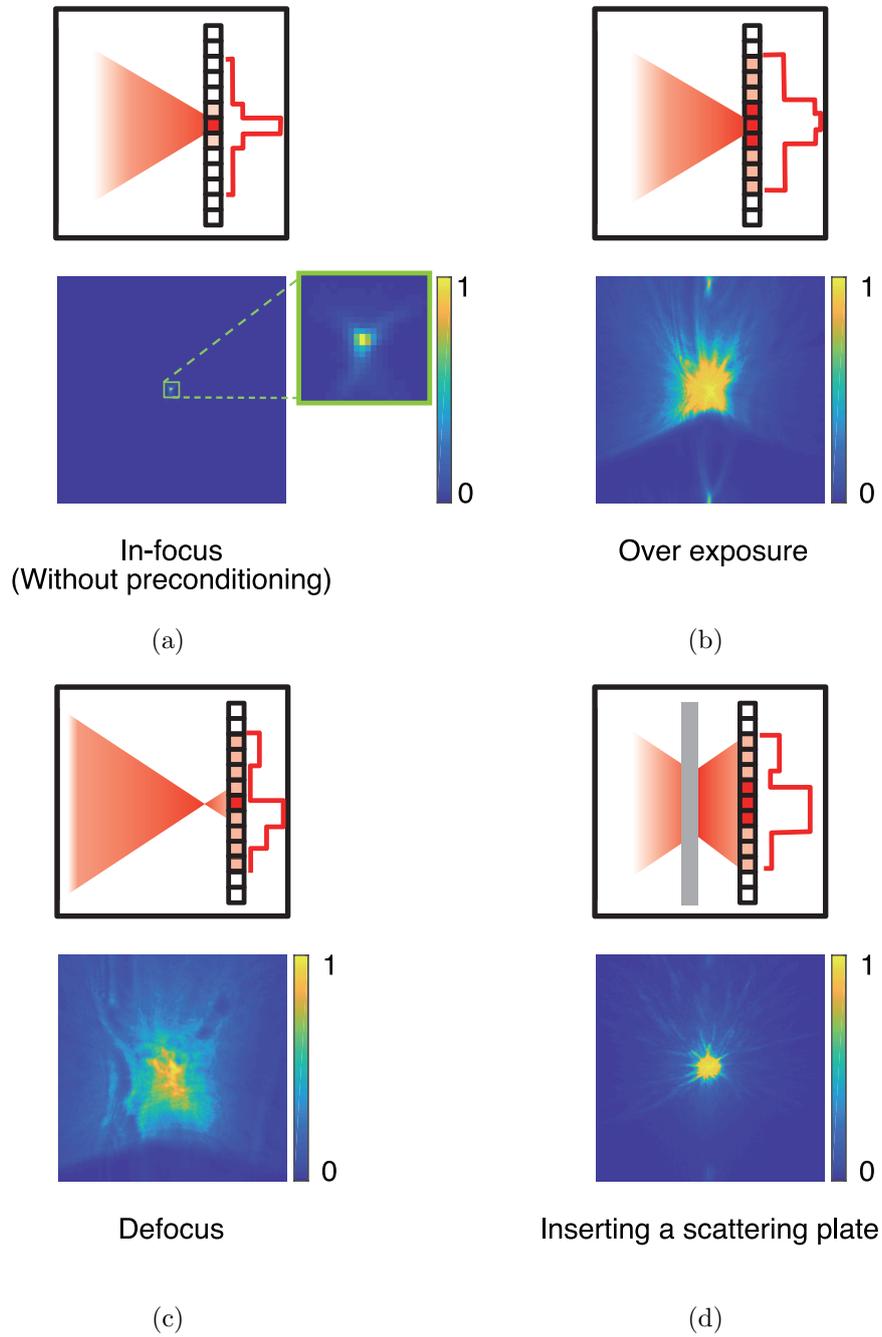


Fig. 2.2 Proposed preconditionings. (a) In-focus (without preconditioning), (b) over exposure, (c) defocus and (d) inserting a scattering plate.

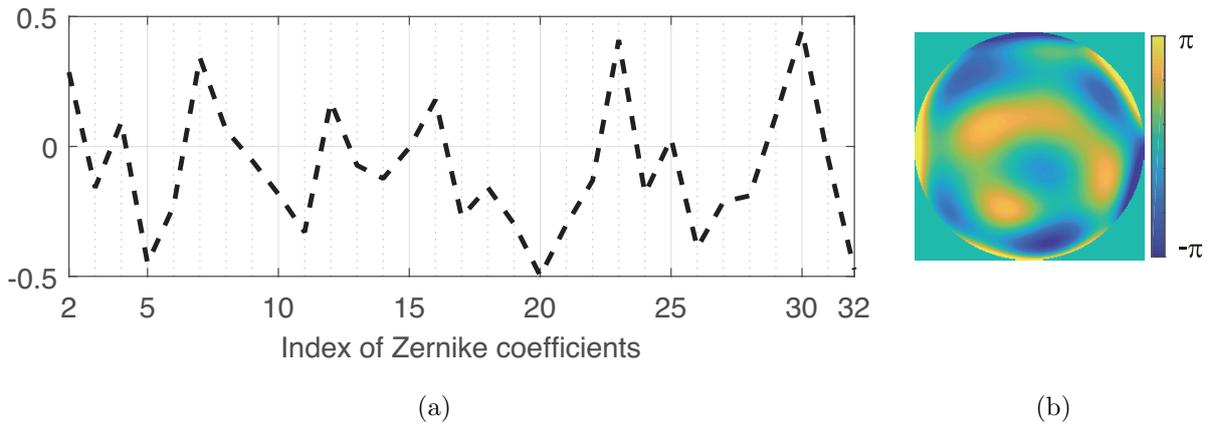


Fig. 2.3 An example pair from the test datasets. (a) The Zernike coefficients and (b) the corresponding phase map, which is normalized in the interval $[-\pi, \pi]$.

任意波面を表示し，入射光波を変調させる．SLM に表示される位相マップは式 (2.3) に基づき，生成した．ゼルニケ多項式の最初の 32 個のゼルニケ係数を使用し，最初の係数であるピストン項はゼロに設定し，残りの 31 個のゼルニケ係数を推定対象とした．各ゼルニケ係数は， $[-0.5 \sim 0.5]$ の範囲でランダムに生成した．このゼルニケ係数から位相マップを生成し，擾乱されて取得された大量の強度画像を学習データおよび，評価用テストデータセットとした．ただし，これらデータセットは，計算機による生成，あるいは，実験による生成のどちらでも取得可能である．計算機による生成の場合は，式 (2.2) - (2.4) に基づき，光源からの光波と位相マップの PSF との畳込み演算により，イメージセンサ面における強度画像を容易に生成可能である．本研究では，実験環境下における推定精度を評価すべく，実験によりデータセットを生成した．実験で使用するゼルニケ係数と対応する位相マップを Fig. 2.3 に示す．

ネットワークの最適化アルゴリズムには Adam を利用した¹⁰⁹⁾．初期学習率は 1×10^{-4} ，バッチサイズは 10，世代数を 40 に設定した．ドロップアウト層のドロップアウト率は 0.2 とした．本提案手法では，Xception による学習を完了させると，単一強度画像のみで SLM に表示される位相波面のゼルニケ係数推定が可能となる．コード実装には MATLAB および Keras を利用した．実行環境は CPU : Intel Xeon 6134 CPU 3.2 GHz, RAM : 192 GB, VRAM : 16 GB (NVIDIA Tesla V100 GPU) である．

2.4.1 点光源を用いた波面計測

まず最初に, Fig. 2.4 に示すような遠方に設置された点光源を想定し, 波面計測をおこなった. この場合, 式 (2.4) の f はデルタ関数, h は擾乱を受けた PSF となる. インコヒーレント白色発光ダイオード (海渡電子製 Kaito2610) からの光波は, Fig. 2.4 に示すようにピンホール (直径 $10 \mu\text{m}$) とコリメートレンズ (焦点距離: 100 mm) を通過し, 位相型 SLM (Holoeye 製 LC2002, ピクセルピッチ: $32 \mu\text{m}$, ピクセル数: 800×600) を照明した. SLM を透過する光波は, イメージングレンズ (焦点距離: 80 mm) を透過し, モノクロ CCD イメージセンサ (PixeLink 製 PL-B953U, ピクセルピッチ: $4.65 \mu\text{m}$, ピクセル数: 1024×768) により強度画像を撮影した. ゼルニケ係数と対応する位相マップ $100,000$ 枚の学習画像データセットを生成した. 同時に $1,000$ 枚のテスト画像データセットも生成した. これらデータセットをランダムに SLM へ表示し強度画像を取得した. 強度画像のピクセル数は 256×256 とした.

2.4.1.1 インフォーカス

Fig. 2.4 (a) に示す光学系にて, ベースラインであるプリコンディショニングを使用しないインフォーカスセットアップで取得された強度画像を利用した推定をおこなった. イメージングレンズ (焦点距離: 80 mm) とイメージセンサ間距離は 8 cm とした. Fig. 2.3 (a) に示したゼルニケ係数により取得された強度画像を Fig. 2.5 (a) に示す. 収差量は僅かなため, 取得画像は回折限界の PSF とほとんど大差はない. 取得画像から推定したゼルニケ係数を Fig. 2.5 (b) に示す. テストデータセットの真値, 推定値間の二乗平均平方根誤差 (RMSE) は 0.142 ± 0.032 であった.

2.4.1.2 過剰露光

次に, Fig. 2.4 (a) に示す光学系に示すように, 2.4.1.1 と同じセットアップで過剰露光によるプリコンディショニングを使用し, 推定を行った. 2.4.1.1 の実験に比べ, 長い露光時間で強度画像を取得した. Fig. 2.3 (a) により与えた収差は, 回折限界 PSF の僅かな偏差をもたらすため, Fig. 2.6 (a) に示すように取得画像上の多くのピクセルが飽和した. 過剰露光プリコンディショニングは, 通常露光時間ではノイズレベルとなり検出不可能な収差を, 顕在化させることに成功している. 取得画像から推定したゼルニケ係数を Fig. 2.6 (b) に示す. テストデータセットの RMSE は 0.036 ± 0.013 であり, 過剰露光によるプリコン

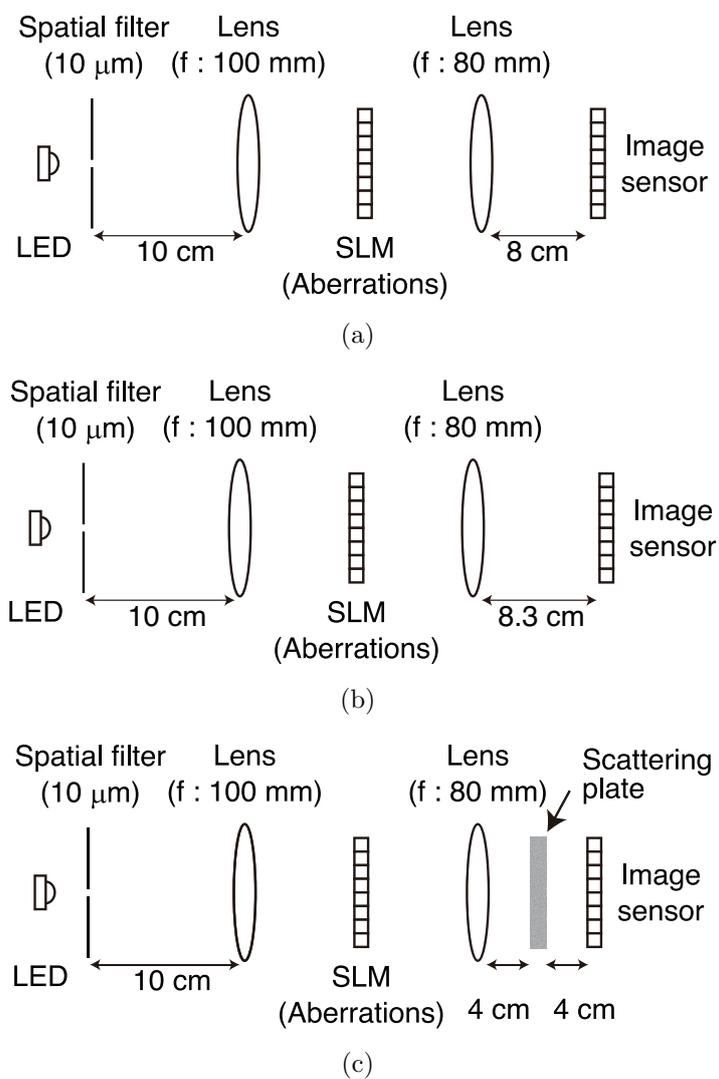


Fig. 2.4 Experimental setup with a point source. Setup of (a) in-focus and overexposure, (b) defocus and (c) inserting a scattering plate.

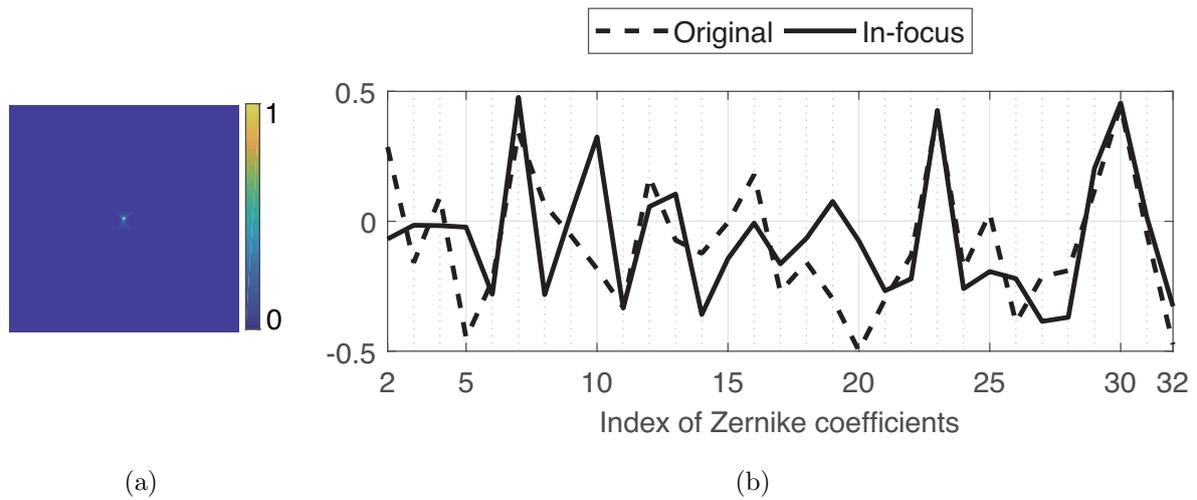


Fig. 2.5 Experimental results in the in-focus setup with a point source. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

ディショニングにより推定精度を向上させることができた。

2.4.1.3 デフォーカス

次に、Fig. 2.4 (b) に示すように、2.4.1.1 のセットアップから僅かにデフォーカスな状態で、推定を行った。デフォーカスによるプリコンディショニングは、収差推定に利用可能なピクセルを更に増加させ、波面計測システムのダイナミックレンジを圧縮することが可能になる。イメージングレンズ (焦点距離 : 80 mm) とイメージセンサ間距離は 8.3 cm とした。Fig. 2.3 (a) により与えた収差により取得された強度画像は、Fig. 2.7 (a) に示すように取得画像上の特徴量を増加させた。取得画像から推定したゼルニケ係数を Fig. 2.7 (b) に示す。テストデータセットの RMSE は 0.040 ± 0.016 であり、インフォーカスセットアップ時に比べ、デフォーカスによるプリコンディショニングにより推定精度を向上させることができた。

2.4.1.4 散乱板挿入

次に、Fig. 2.4 (c) に示す光学系において、イメージングレンズとイメージセンサ間に散乱板を挿入することにより、散乱板挿入によるプリコンディショニングを使用した推定を行う。イメージングレンズ (焦点距離 : 80 mm) と散乱板間距離は 4 cm、散乱板とイメー

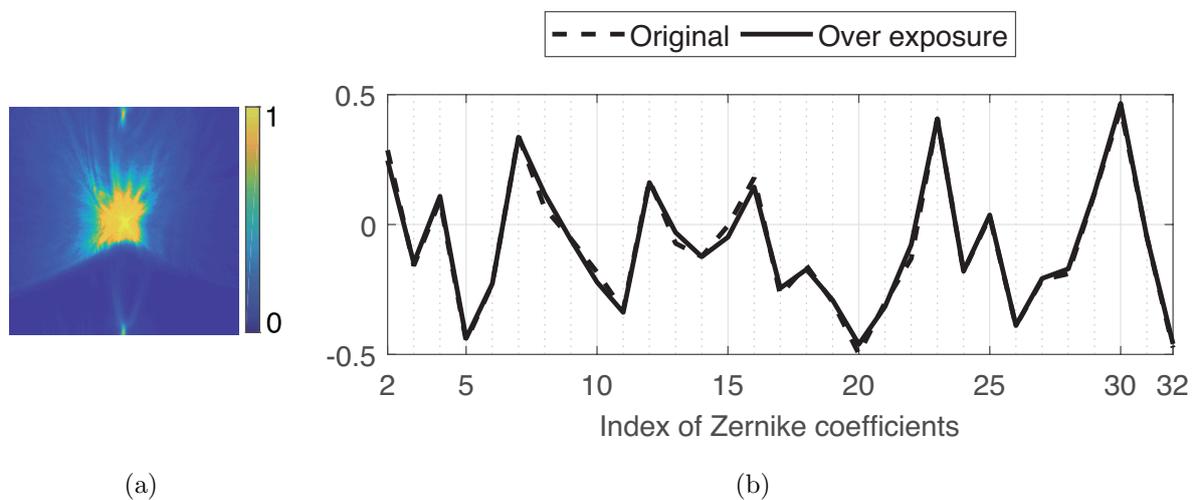


Fig. 2.6 Experimental results in the overexposure setup with a point source. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

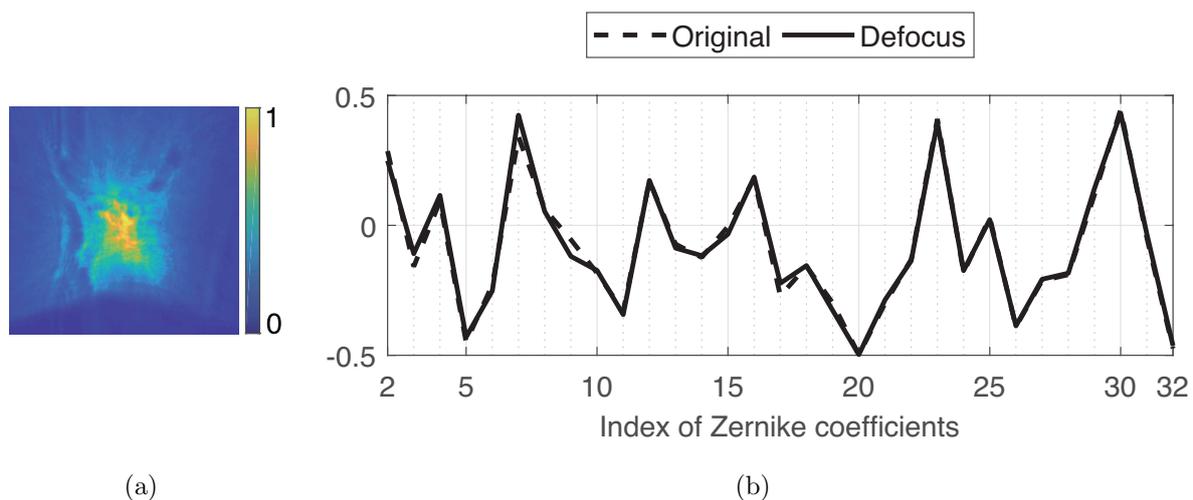


Fig. 2.7 Experimental results in the defocus setup with a point source. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

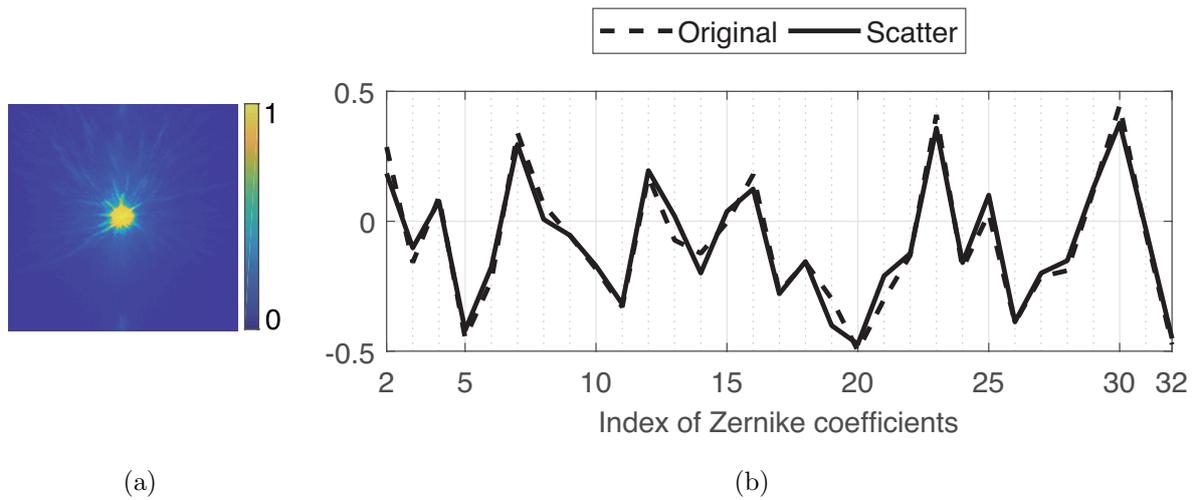


Fig. 2.8 Experimental results in the inserting a scattering plate setup with a point source. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

ジセンサ間距離は 4 cm とした。Fig. 2.3 (a) により与えた収差により取得された強度画像を Fig. 2.8 (a) に示す。取得画像から推定したゼルニケ係数を Fig. 2.8 (b) に示す。テストデータセットの RMSE は 0.057 ± 0.018 であり、インフォーカスセットアップ時に比べ、推定精度を向上させることができた。

2.4.2 2次元光源を用いた波面計測

Fig. 2.10 に示す光学系にて、オブジェクトとして 2次元光源を使用した DLWFS の実証をおこなう。この場合、式 (2.4) の f は 2次元光源、 h は擾乱を受けた PSF となる。イメージセンサ面に与える影響は式 (2.4) の f および h が畳込み演算されて表現される。この場合の波面計測はより一般化されることになるが、点光源を使用したときに比べ、PSF のローパスフィルタとして機能する 2次元光源を使用する場合、取得画像にボケを生じてさせてしまうため、推定は困難となる。したがって、学習データセット数を 1,000,000 枚に増やして推定をおこなった。ただし、これらデータセットは、計算機による生成、あるいは、実験による生成のどちらでも取得可能である。計算機による生成の場合は、式 (2.2) - (2.4) に基づき、光源からの光波と位相マップの PSF との畳込み演算により、イメージセンサ面における強度画像を容易に生成可能である。

2つの SLM (Holoeye 製 LC2012, ピクセルピッチ: $36 \mu\text{m}$, ピクセル数: 1024×768) を使用して、任意のオブジェクトと擾乱波面を生成した。任意の 2次元光源を生成する

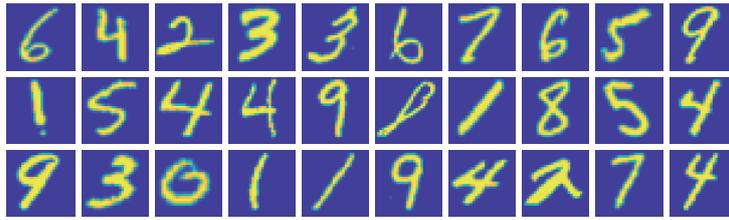


Fig. 2.9 Examples of object images from the EMNIST database.

ため、Fig. 2.1 に示すようにクロスニコル配置された偏光板間に1つ目のSLMを設置し振幅モードとして使用し、照明としてインコヒーレント白色発光ダイオード(海渡電子製Kaito2610)を用いた。照明強度を一様化すべく、照明前方にディフューザを設置した。2つ目のSLMは位相モードで利用し、点光源の場合と同様に擾乱波面を表示した。1つ目のSLMとイメージングレンズ(焦点距離: 85 mm)の距離は79 cm, 2つ目のSLMはイメージングレンズの直前に設置した。2つ目のSLMを透過した光波は、イメージングレンズを透過し、イメージセンサによって強度画像として取得される。

2次元光源としてEMNISTデータベースから取得した手書き数字を利用した¹¹⁰⁾。データベース内の画像ピクセルサイズは 28×28 で、1つ目のSLMの中央領域に表示した。学習データセットとテストデータセットの画像枚数はそれぞれ1,000,000枚, 1,000枚とし、データ重複は生じさせていない。2次元光源の画像例をFig. 2.9に示す。取得される強度画像サイズは点光源の実験と同様に 256×256 とした。

2.4.2.1 インフォーカス

Fig. 2.10 (a) に示す光学系にて、ベースラインであるプリコンディショニングを使用しないインフォーカスセットアップで取得された強度画像を利用した推定をおこなった。イメージングレンズ(焦点距離: 85 mm)とイメージセンサ間距離は、レンズの公式から9.5 cmとした。Fig. 2.3 (a) に示したゼルニケ係数で取得された強度画像をFig. 2.10 (a) に示す。取得画像から推定したゼルニケ係数をFig. 2.10 (b) に示す。Fig. 2.10 (b) からわかるように、ゼルニケ係数の推定には失敗した。テストデータセットの真値、推定値間の二乗平均平方根誤差(RMSE)は 0.288 ± 0.024 であった。

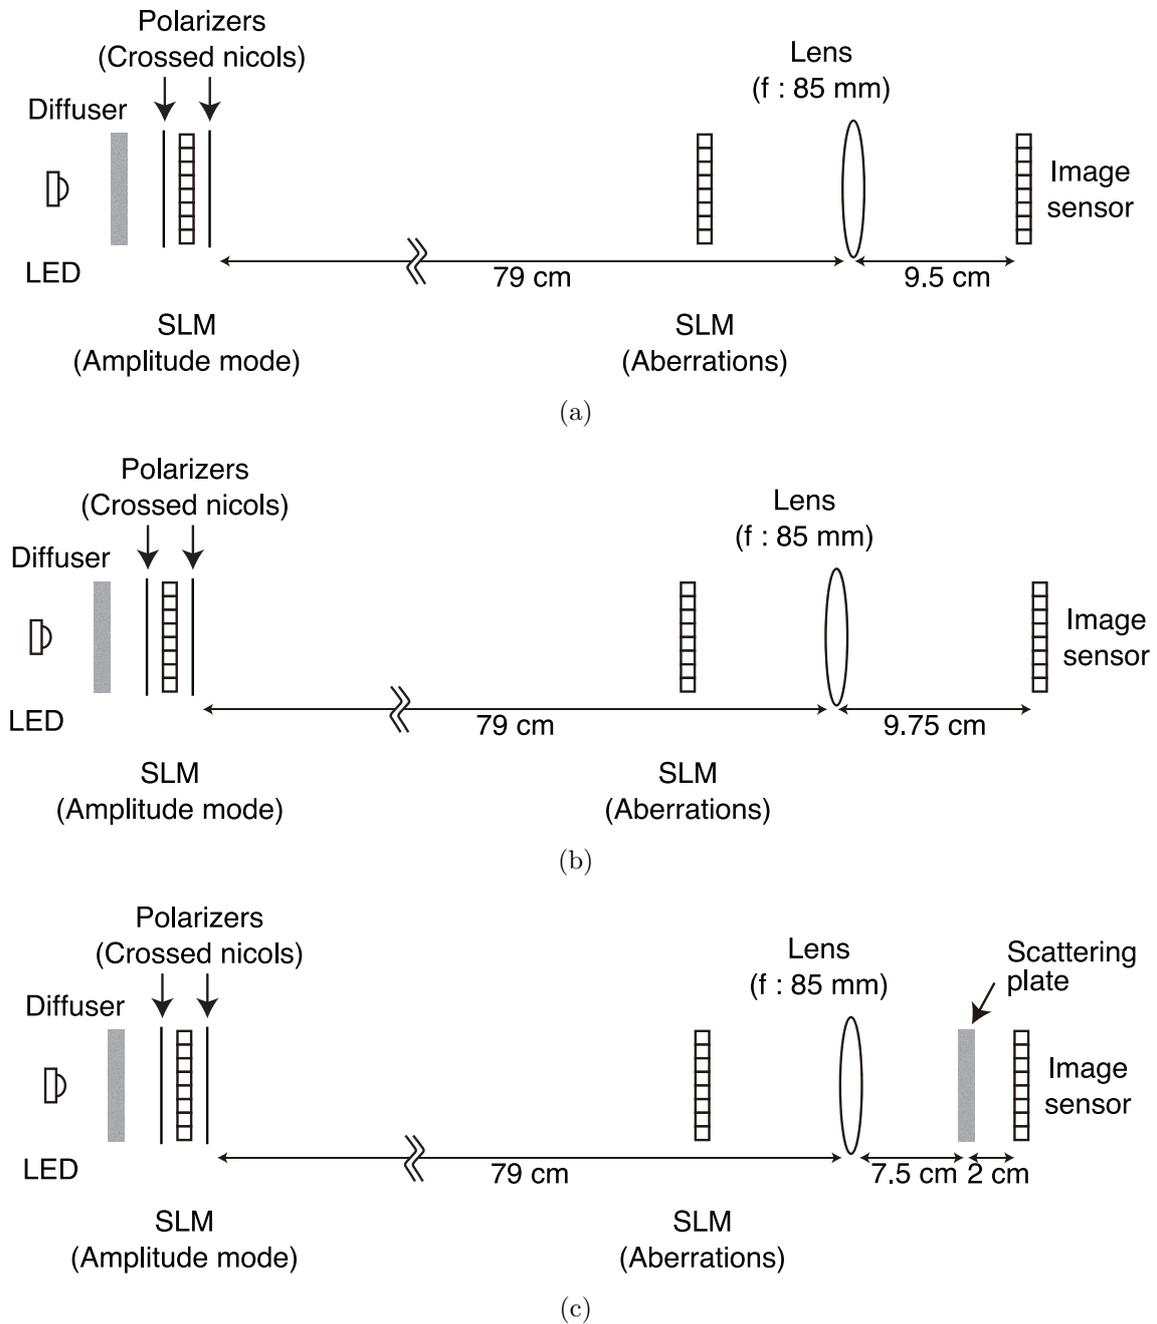


Fig. 2.10 Experimental setup with extended sources. (a) In-focus and overexposure, (b) defocus and (c) inserting a scattering plate.

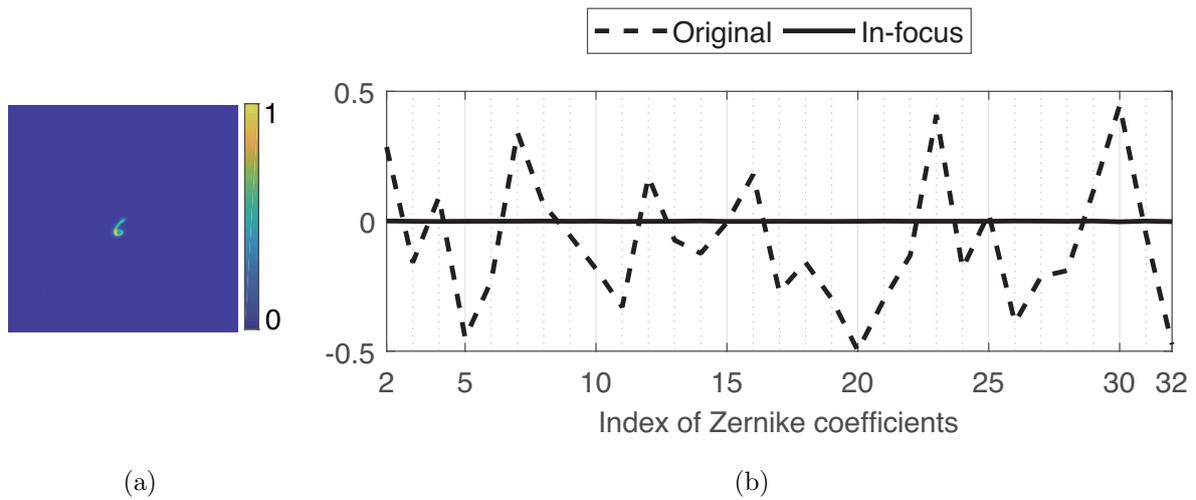


Fig. 2.11 Experimental results in the in-focus setup with extended sources. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

2.4.2.2 過剰露光

Fig. 2.10 (a) に示すように、2.4.2.1 と同じセットアップで露光時間を長くとり、過剰露光によるプリコンディショニングを使用した推定を行った。Fig. 2.3 (a) に示したゼルニケ係数で取得された強度画像を Fig. 2.12 (a) に示す。取得画像から推定したゼルニケ係数を Fig. 2.12 (b) に示す。テストデータセットの RMSE は 0.214 ± 0.051 であった。このことから、2次元光源を使用した場合でも、過剰露光によるプリコンディショニングに用いることにより、推定精度を向上させることができた。

2.4.2.3 デフォーカス

Fig. 2.10 (b) に示すように、イメージングレンズとイメージセンサ間距離を 9.75 cm とし、デフォーカスによるプリコンディショニングを使用した推定をおこなった。Fig. 2.3 (a) に示したゼルニケ係数で取得された強度画像を Fig. 2.13 (a) に示す。取得画像から推定したゼルニケ係数を Fig. 2.13 (b) に示す。テストデータセットの RMSE は 0.099 ± 0.064 であった。デフォーカスによるプリコンディショニングに用いることにより、インフォーカス状態と比較して推定精度を向上させることができた。

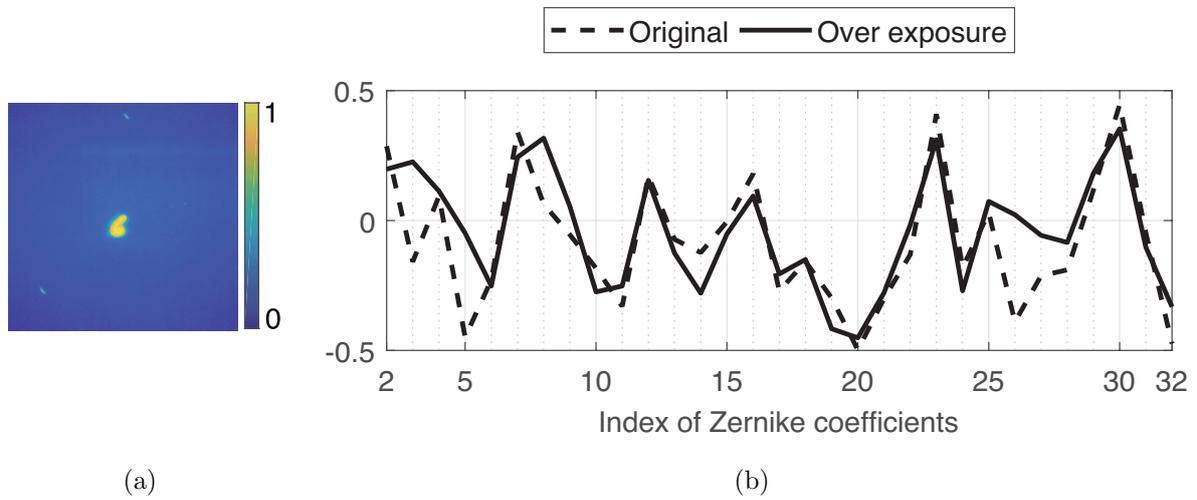


Fig. 2.12 Experimental results in the overexposure setup with extended sources. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

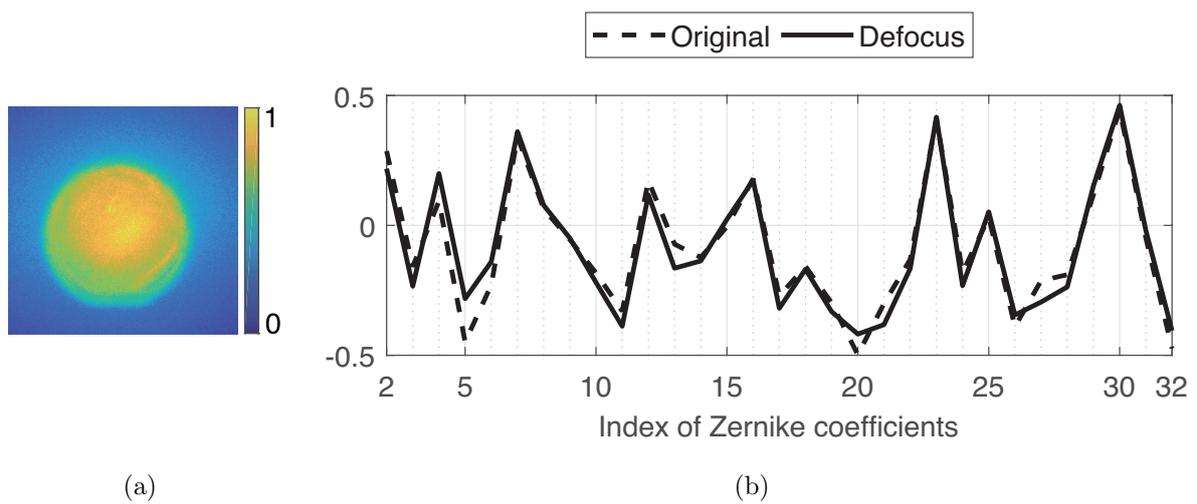


Fig. 2.13 Experimental results in the defocus setup with extended sources. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

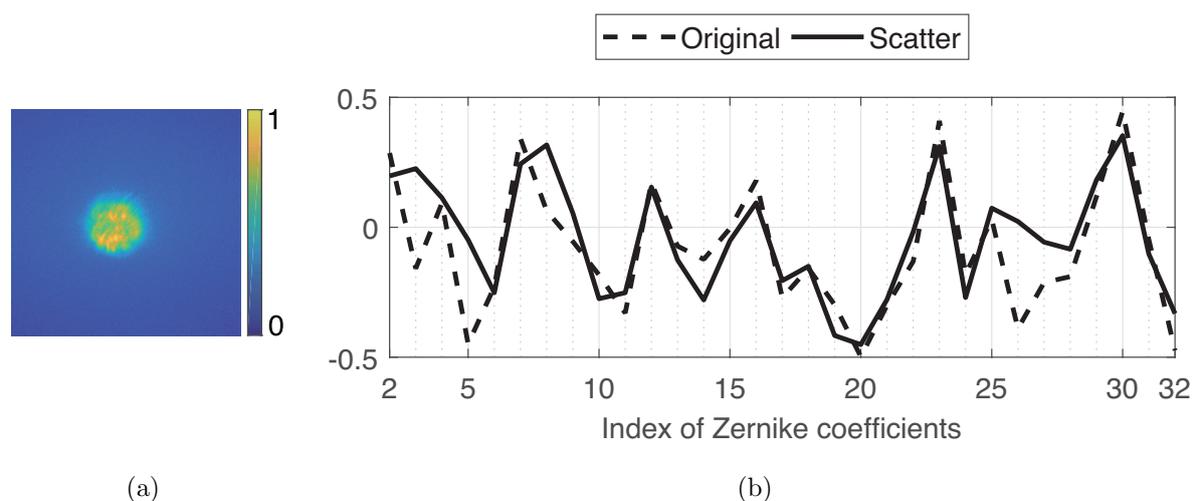


Fig. 2.14 Experimental results in the inserting a scattering plate setup with extended sources. (a) The captured image with the Zernike coefficients in Fig. 2.3 (a) and (b) the estimated Zernike coefficients.

2.4.2.4 散乱板挿入

Fig. 2.10 (c) に示すように、インフォーカスのセットアップに対し、イメージングレンズ後方 7.5 cm の場所に散乱板を挿入し、散乱板挿入プリコンディショニングによる推定を行った。Fig. 2.3 (a) に示したゼルニケ係数で取得された強度画像を Fig. 2.14 (a) に示す。取得画像から推定したゼルニケ係数を Fig. 2.14 (b) に示す。テストデータセットの RMSE は 0.195 ± 0.064 であった。散乱板挿入によるプリコンディショニングに用いることでも、インフォーカス状態と比較して推定精度を向上させることができた。

2.5 考察

2.4.1 および 2.4.2 で推定した RMSE の一覧を表 2.1 に、式 (2.3) により波面に変換した後の推定波面精度を表 2.2 に示す。表 2.1, 表 2.2 に示すように、程度の違いはあるが全てのプリコンディショニングでゼルニケ係数の推定精度が向上していることが確認できる。点光源を使用した波面計測は、PSF のローパスフィルタとして機能する 2次元光源を使用した波面計測よりも優れた精度を示した。点光源を利用したプリコンディショニングによる波面計測では平均 3.2 倍、2次元光源を利用したプリコンディショニングによる波面計測では平均 1.7 倍の改善効果を確認した。デフォーカスによるプリコンディショニングは、その他のプリコンディショニングと比較して、点光源および 2次元光源の両方の

Table 2.1 Summary of the accuracies (RMSEs) of the estimated Zernike coefficients in the experiments.

	In-focus	Overexposure	Defocus	Scatter
Point source	0.142 ± 0.032	0.036 ± 0.013	0.040 ± 0.016	0.057 ± 0.018
Extended sources	0.288 ± 0.024	0.214 ± 0.051	0.099 ± 0.064	0.195 ± 0.064

Table 2.2 Summary of accuracies (RMSEs : rad) of the equivalent wavefronts from the Zernike coefficients estimated in the experiments.

	In-focus	Overexposure	Defocus	Scatter
Point source	1.136 ± 0.197	0.563 ± 0.182	0.555 ± 0.188	0.726 ± 0.204
Extended sources	1.367 ± 0.111	1.332 ± 0.204	0.810 ± 0.288	1.251 ± 0.235

ケースで、インフォーカスセットアップの推定よりも高精度な推定を行うことが出来た。

2次元光源およびデフォーカスによるプリコンディショニングにより得られた推定精度に対する学習枚数の影響を Fig. 2.15 に示す。学習枚数を増加させると長時間の計算時間が必要になるが、この計算は学習時に限り必要であり、学習完了後は反復処理なしで推定が可能となる。本実験では前述した計算機により単一強度画像から推定を行い、その推定時間は 9.2 ms であった。この推定時間はネットワークの最適化あるいは専用の計算機を利用することにより、大幅に高速化可能である。

Fig. 2.15 には、学習に含まれない未知の収差が存在する場合の推定に与える影響を示している。32 個のゼルニケ係数で擾乱させた波面による強度画像に対し、学習では最初の 15 個あるいは 21 個のゼルニケ係数を使用して学習し、テスト画像にて評価をおこなった。未知のゼルニケ係数が推定精度へ与える影響は僅かであるが、学習枚数を増加させることでその影響を低減させることができることが示されている。自然乱流における高次のゼルニケ係数の大きさは、低次と比較して小さいことが知られており、学習時に考慮する係数よりも高次の係数の影響を無視することができる¹¹¹⁾。

2.6 結論

本章では、波面計測に機械学習を導入することにより、波面計測の設計自由度を拡張することが可能な波面センサを提案した。DLWFS では提案したプリコンディショニング単体、従来型プリコンディショニング単体、提案したプリコンディショニングを複数組合せ

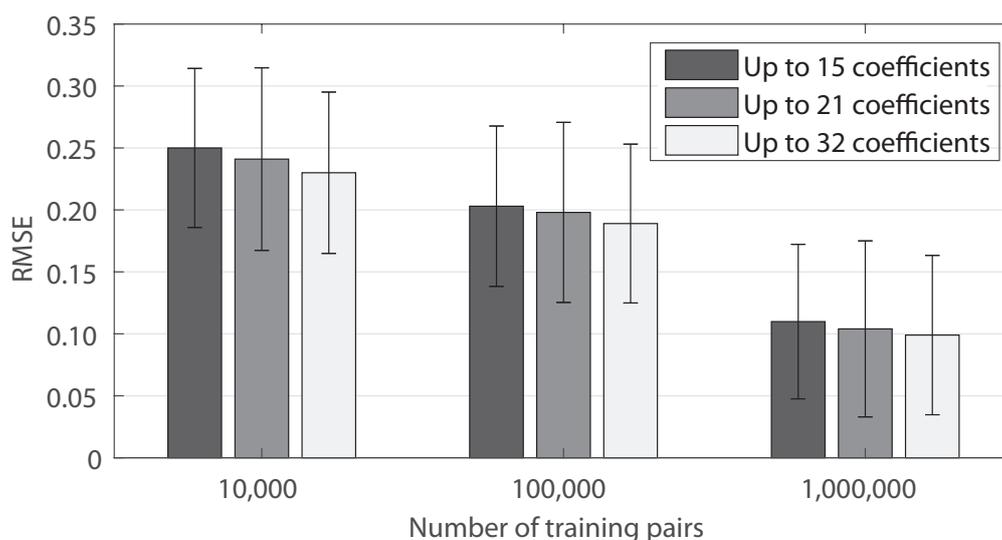


Fig. 2.15 Relationship between the number of training pairs and the accuracy obtained from the estimated coefficients when training for 15, 21 and 32 coefficients, while testing on wavefronts with 32 coefficients using extended sources and the defocus preconditioning.

た形式，従来型プリコンディショニングを複数組合せた形式，あるいは提案したプリコンディショニングと従来型プリコンディショニングとの融合型でも使用することが可能であり，これまでの波面センサの設計自由度を大幅に改善させることができた．最先端である畳込みニューラルネットワークとプリコンディショニングを介して取得された単一強度画像により，入射波面のゼルニケ係数を直接推定することが可能となった．

本手法では，従来から使用されている点光源に加え，より汎用的な2次元光源を利用し，過剰露光，デフォーカス，散乱板挿入のプリコンディショニングを利用するDLWFSの実験をおこなった．プリコンディショニングを使用した全条件において，インフォーカスセットアップの推定よりも，精度を大幅に改善できることを示すことが出来た．本研究では，実験によって学習データセット生成をおこなったが，計算機による学習データセット生成を行うことにより，学習データセットを生成する時間コストは大幅に削減可能である．計算機による生成の場合は，光源からの光波と位相マップのPSFとの畳込み演算により，イメージセンサ面における強度画像を容易に生成可能である．

一般化されたプリコンディショニングは，今後の革新的な波面センサの設計を可能とする．本手法は，レンズアレイやピラミッド型プリズムなど，従来の波面センサですでに使用されている光学素子であっても使用可能である．提案するDLWFSのフレームワークの実験による実装では，正確なアライメントや精密光学素子を必要とせずに，マウントさ

れた状態で学習可能であるという利点を持ち、学習が装置アライメント等のキャリブレーションも担う。したがって、提案されたフレームワークは、特に生物医学、天文学、および光通信にむけた補償光学など、非常に広範囲な分野に適用可能な波面センサを簡素化させ、様々な分野の光波計測に寄与する。

第 3 章

深層学習を用いた非反復型位相回復と反復型位相回復の比較解析

3.1 緒論

本章では，回折イメージングにおける位相回復手法に対し，深層学習を導入した場合の再構成精度，ノイズ耐性および計算時間に関して述べる．

光学現象は，波動光学を使用して記述することが可能であるが，イメージセンサは光波の強度のみを検出し，位相については取得することができない³⁵⁾．デジタルホログラフィを代表とする干渉計測法では，光波の振幅と位相の両方を取得可能であることから広く普及している³⁶⁻³⁸⁾．このような方法は定量位相イメージング手法の一例であり，ラベルフリーの生体医療イメージング等へ利用されている^{39, 41)}．ただし，干渉計測法の欠点として，参照光を利用するために，光学系が複雑化してしまうことが挙げられる．

一方，回折イメージングは，回折光の強度画像を使用し，参照光なしで光波の複素振幅，つまり振幅と位相を測定する手法である⁴⁵⁻⁴⁸⁾．強度画像から位相を回復する逆問題は位相回復問題として知られている⁴⁹⁻⁵⁴⁾．過去においては，X線領域での高精度な結像光学素子およびコヒーレント光源の製造が困難であったことから，X線イメージングには回折イメージングが使用されてきた^{55, 56)}．近年では，可視領域におけるレンズレスイメージングとスペックル相関イメージングに対し位相回復技術が導入されている⁵⁷⁻⁶²⁾．

従来型の位相回復アルゴリズムは，物体面とセンサー面の反復計算を利用し，強度画像から位相を回復するが，十分な収束には多くの反復回数が必要であった^{52, 53)}．一方，近年では深層学習などの機械学習が，ロバストかつ高速な位相回復手法として使用され始めている．C. A. MetzlerやÇ. Işilらは，反復演算中に機械学習を組み込み，ノイズ除去としての機能を果たすことを見出した^{112, 113)}．A. SinhaやM. J. Cherukaraらは，位相回復の逆問題を解くための解析手法として機械学習を利用した^{28, 114)}．機械学習をこのような逆問題を解くための解析手法としての利用によって，従来型の反復型位相回復よりも高速な

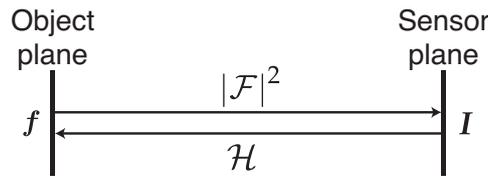


Fig. 3.1 Flow of imaging and reconstruction.

非反復型位相回復を実現し，リアルタイム回折イメージング，散乱体イメージング，計算機合成ホログラム，波面センシング，パルス測定にも使用されている^{25, 28, 29, 31, 114–117}．同時に，位相回復以外の光学センシングへも積極的な導入がなされている^{118–121}．

本章では，反復型位相回復手法と深層学習を導入した非反復型位相回復手法について数値実験による再構成精度，ノイズ耐性と計算時間の観点から比較を行った．3.2節では，反復型，非反復型位相回復手法についてまとめる．3.3節では，数値実験により，各手法毎の比較を行った．さらに，ノイズ耐性向上を目的に，ノイズあり学習データセットを使用した学習器を構築し，その性能評価をおこなった．

3.2 位相回復

本研究での数値実験では，Fig. 3.1に示す光学系を仮定する．対象 f からの光波は十分に遠くに配置されたセンサー面に伝搬し，単一強度画像として取得される．この計測プロセスは

$$\mathbf{I} = |\mathbf{F}|^2 = |\mathcal{F}[f]|^2, \quad (3.1)$$

とあらわされる．ここで， $\mathcal{F}[\bullet]$ はフーリエ変換， \mathbf{F} はフラウンホーファー回折後の対象のフーリエスペクトル， \mathbf{I} は取得された強度画像， $|\bullet|^2$ は要素ごとの強度演算子である．ここで，対象は複素数表現したときに実部のみをもつ物体かつ非負であると仮定する．この仮定は，天文学，結晶工学の分野では一般的とされている^{52–54}．この仮定を利用することにより，従来手法における解の収束性および一意性を向上させることができる．式 (3.1) の逆関数は，

$$f = \mathcal{H}[\mathbf{I}], \quad (3.2)$$

と表すことができる．ここで， $\mathcal{H}[\bullet]$ は位相回復のための逆関数を示す．

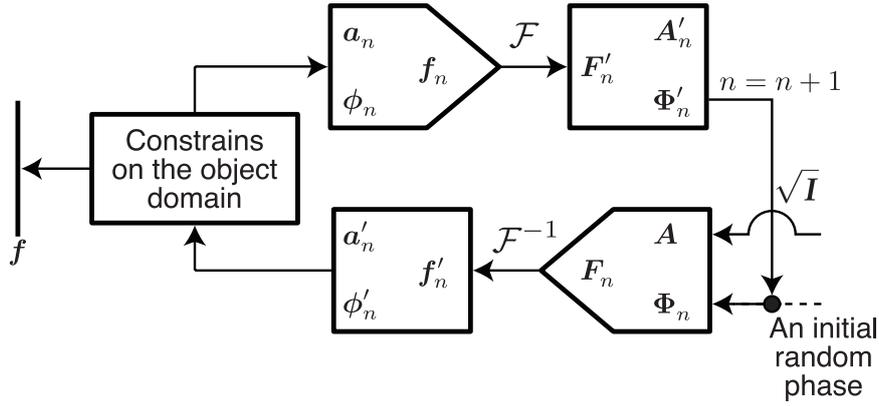


Fig. 3.2 Diagram of a conventional iterative phase retrieval method.

3.2.1 反復型回復

本研究では、Fig. 3.2に示すような、Error Reduction法 (ER法) および Hybrid Input-Output法 (HIO法) を反復型位相回復手法として使用した⁵²⁾。この場合、逆関数 \mathcal{H} を求める過程は、次のような反復プロセスとなる。

- (1) フーリエスペクトルの初期値 \mathbf{F}_n を $\mathbf{F}_n = \mathbf{A} \circ \exp(j\Phi_n)$ として与える。 \circ は要素積演算子を表す。ここで、 \mathbf{A} は振幅であり、 \sqrt{I} である。 Φ_n は位相であり、初期値はランダム値とする。 n は反復回数であり、初期値は1とする。
- (2) 中間推定される対象 f'_n は $f'_n = \mathcal{F}^{-1}[\mathbf{F}_n]$ となる。ここで、 \mathcal{F}^{-1} はフーリエ逆変換である。
- (3) 物体面での拘束により、中間推定された対象 f'_n は推定対象 f_n へと更新する。詳細は後述する。
- (4) 中間推定されるフーリエスペクトル \mathbf{F}'_n は $\mathbf{F}'_n = \mathcal{F}[f_n]$ とあらわす。
- (5) フーリエ面にて、振幅を \sqrt{I} へと置換し、推定フーリエスペクトル \mathbf{F}_n へ更新し、 n を1だけ増加させる。

ステップ(2) - (5) は誤差が収束するまで反復する。

ER法の場合、 n 回目のステップ(3)における更新ルールは、

$$f_n(x, y) = \begin{cases} f'_n(x, y), & (x, y \notin \eta), \\ 0, & (x, y \in \eta), \end{cases} \quad (3.3)$$

である。ここで η は拘束条件に違反する空間座標集合であり、 x および y はそれぞれ対象上の座標を示す。HIO 法の場合、 n 回目のステップ (3) における更新ルールは、

$$f_n(x, y) = \begin{cases} f'_n(x, y), & (x, y \notin \eta), \\ f_{n-1}(x, y) - \beta f'_n(x, y), & (x, y \in \eta), \end{cases} \quad (3.4)$$

である。ここで、 β はフィードバック係数である。本数値実験では、対象の拘束として複素数表現したときに実部のみをもつ物体かつ非負とする⁵²⁻⁵⁴。

3.2.2 機械学習を用いた非反復型位相回復

近年、逆問題は機械学習を用いたプロセスにより、解決が図られている^{25, 28, 31, 113-116}。位相回復に機械学習を利用することにより、逆問題は反復演算することなく解くことが可能になる。本研究では、ResNet と呼ばれる畳込みニューラルネットワークを使用する^{28, 31, 122}。ResNet は実用的なネットワークアーキテクチャとして知られている。様々な場面で応用利用されており、スキップ結合を利用した残差学習により、学習段階での勾配の消失/爆発問題を防ぐことが可能とされている。機械学習を用いた非反復型位相回復の場合、逆関数 \mathcal{H} は ResNet の学習データセットを利用することにより、非反復型回帰演算としてあらわされる。本研究では、Fig. 3.3 に示すように深さの異なる2種類の ResNet を構築し、計算コストとノイズ耐性の比較をおこなった。

1つ目のネットワークは Fig. 3.3 (a) に示すように、1組のダウンサンプリング、アップサンプリングプロセスをもつネットワークとした。このネットワークを本研究では、ResNet1 と定義する。2つ目のネットワークは Fig. 3.3 (b) に示すように、2組のダウンサンプリング、アップサンプリングプロセスをもつネットワークとした。このネットワークを本研究では、ResNet2 と定義する。ここで、“D” は Fig. 3.3 (c) に示すダウンサンプリングブロック、“U” は Fig. 3.3 (d) に示すアップサンプリングブロック、“S” は Fig. 3.3 (e) に示す畳込みスキップ層を示している。また、“BatchNorm” はバッチ正規化層¹²³、“ReLU” は活性化関数を示している¹²⁴。“Conv(s, l)” および “TConv(s, l)” はそれぞれ2次元畳込み演算層、2次元転置畳込み演算層であり、 s はフィルタサイズ、 l はストライドである。

3.3 数値実験による比較と考察

計算機による数値実験を実施した。本数値実験で用いる機械学習は Fig. 3.3 に示す異なる深さの ResNet とした。更に、ノイズ有り、ノイズ無しの学習データセットを使用したネットワークを構築し、その性能を比較した。ノイズ有り学習データセットでは、白

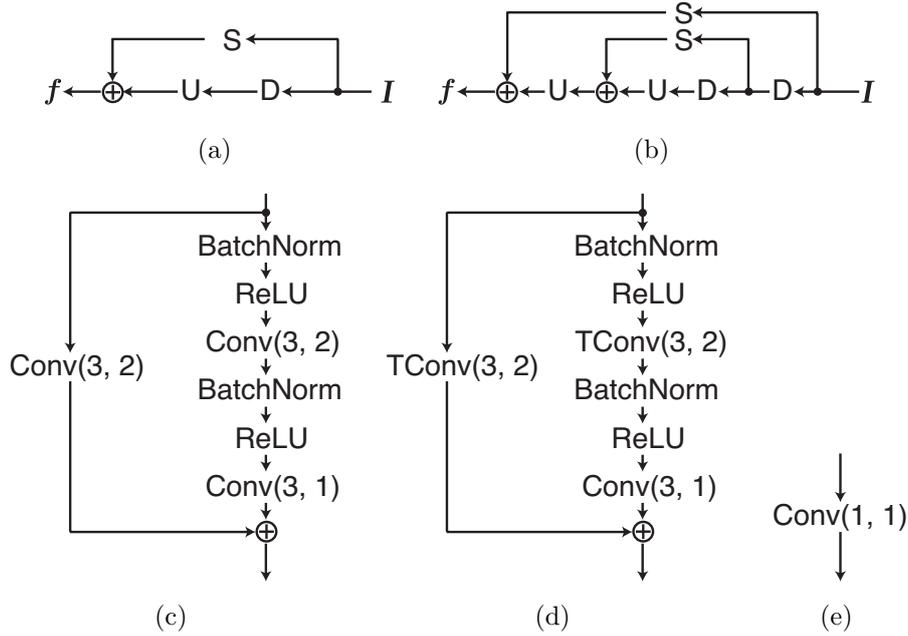


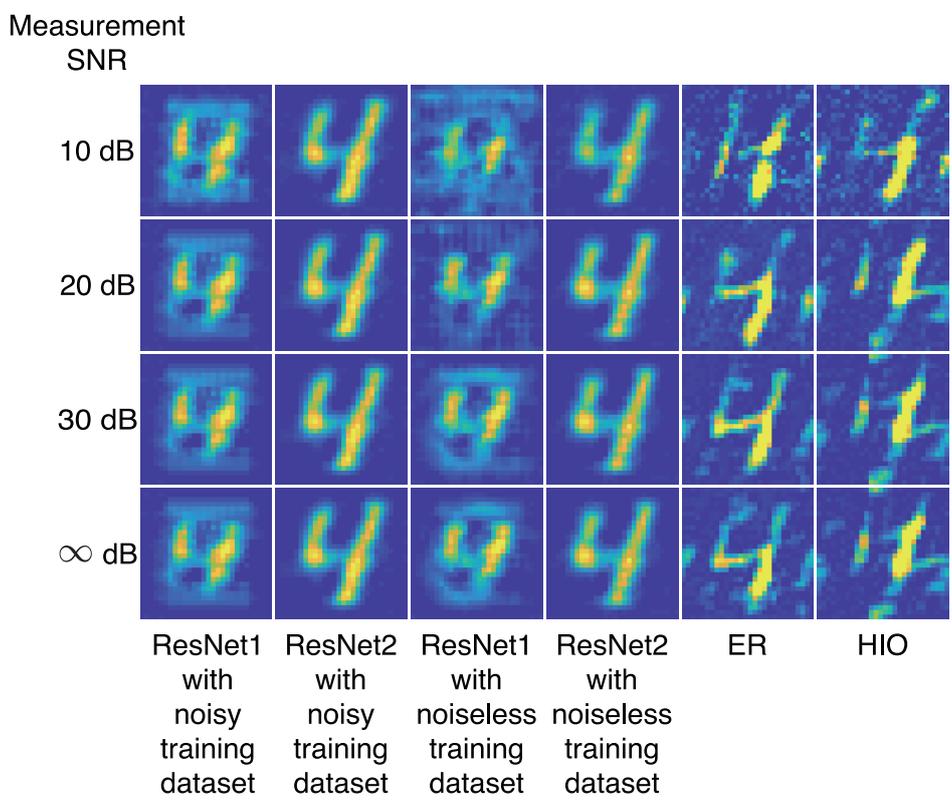
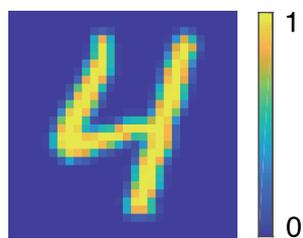
Fig. 3.3 Diagram of a non-iterative machine-learning-based phase retrieval method. (a) ResNet1, (b) ResNet2, (c) D-block, (d) U-block and (e) S-block.

色ガウスノイズを学習画像に加えた。そのノイズレベル (SNR : Signal-to-noise ratio) は 10 dB ~ 30 dB のランダム値とした。

対象として用いる画像は、Fig. 3.4 (a) に示す EMNIST データベースからランダムに取得した手書き数字を利用した¹¹⁰⁾。原画像および取得画像サイズは 28×28 とした。学習データセットは 200,000 組、テストデータセットは 1,000 組の原画像および取得画像のペアとした。なお、これらのデータセットは重複していない。

ネットワークの最適化学習アルゴリズムは Adam を使用した¹⁰⁹⁾。初期学習率は 1×10^{-5} 、バッチサイズは 100、世代数は 100 とした。最適化の損失関数は平均二乗誤差とした。ER 法および HIO 法が十分に収束したときの反復回数は 200 であった⁵¹⁾。式 (3.4) のフィードバック係数 β は 0.9 とした。本数値実験は全て Python および Keras により実装した。実行環境は CPU : Intel Xeon 6134 CPU 3.2 GHz, RAM : 192 GB, VRAM : 16 GB (NVIDIA Tesla V100 GPU) である。

機械学習による非反復型位相回復手法および反復型位相回復の評価は、異なる計測ノイズが加わったテスト画像によって比較をおこなった。ノイズレベルは 10, 20, 30 および ∞ dB とした。Fig. 3.4 (b) に再構成結果を示す。ER 法および HIO 法による位相回復



(b)

Fig. 3.4 Simulation results. (a) Original and (b) estimated images.

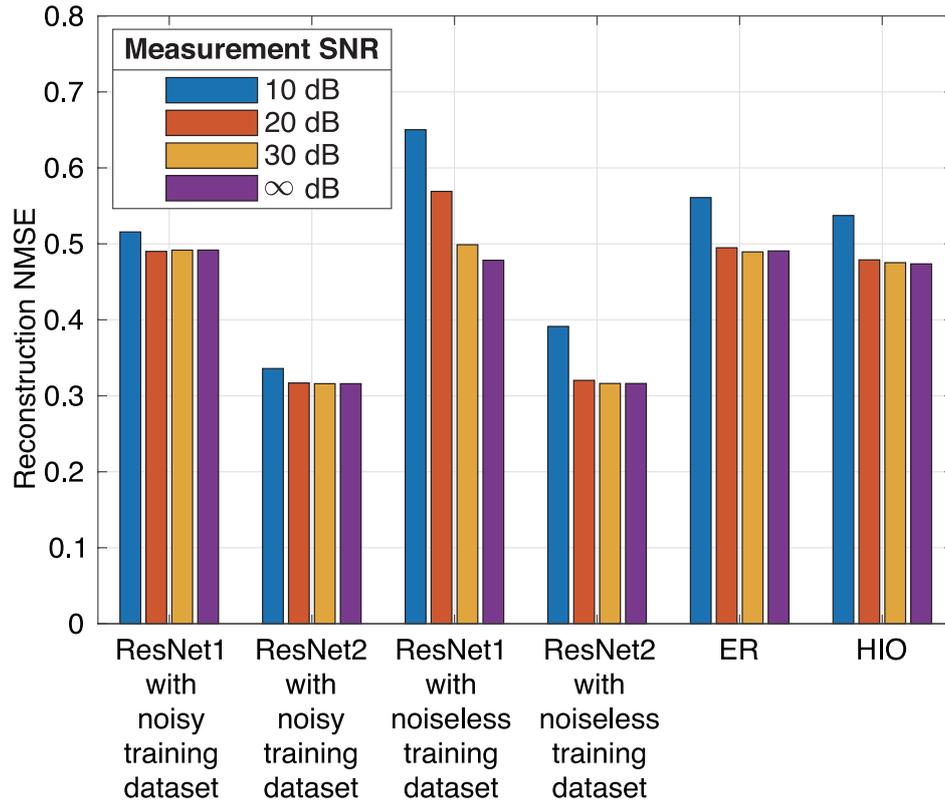


Fig. 3.5 Relationship between the estimation errors (NMSEs) and the measurement SNRs.

では、空間シフトおよび反転が生じる。それら空間シフトおよび反転は、相互相関演算によって補償した。Fig. 3.4 (b) に示すように、ResNet1, ER 法, HIO 法の再構成結果においては、アーティファクトが強く生じてしまっている。再構成精度の定量評価には正規化平均二乗誤差 (NMSE : Normalized mean squared error) を使用した¹²⁵⁾。NMSE は

$$\text{NMSE} = \frac{\sum_{x=1}^M \sum_{y=1}^N (\hat{f}(x, y) - f(x, y))^2}{\sum_{x=1}^M \sum_{y=1}^N f(x, y)^2}, \quad (3.5)$$

とあらわされる。ここで、 \hat{f} , f はそれぞれ物体面における位相回復により得られた推定対象, オリジナルの対象を示す。また、 M と N はそれぞれ x 軸, y 軸に沿った要素数である。テストデータ全体の平均 NMSE を Fig. 3.5 および Table 3.1 に示す。Fig. 3.4, Fig. 3.5 および Table 3.1 の結果は、ResNet2 による位相回復は、ノイズを含んだテストデータであっても、高精度かつロバストに行えていることを示しており、ER 法や HIO 法よりも優れた結果であった。また、深いネットワークである ResNet2 は浅いネットワー

Table 3.1 Summary of the estimation accuracies (NMSEs) shown in Fig. 3.5.

	Measurement SNR			
	10 dB	20 dB	30 dB	∞ dB
ResNet1 with noisy training dataset	0.516	0.490	0.492	0.492
ResNet2 with noisy training dataset	0.336	0.317	0.316	0.316
ResNet1 with noiseless training dataset	0.650	0.569	0.499	0.478
ResNet2 with noiseless training dataset	0.391	0.320	0.316	0.316
ER	0.561	0.495	0.489	0.491
HIO	0.537	0.479	0.475	0.474

Table 3.2 Summary of relationship between the number of training pairs and the NMSE of ResNet2 with the noisy training dataset shown in Fig. 3.6.

Number of training pairs	Measurement SNR			
	10 dB	20 dB	30 dB	∞ dB
2000	0.912	0.868	0.865	0.865
20000	0.438	0.427	0.427	0.426
200000	0.336	0.317	0.316	0.316

クである ResNet1 よりも高精度に位相回復が行えることもわかった。ResNet2 の NMSE は ResNet1, ER 法, HIO 法よりも 1.6 倍優れていた。更に, ノイズ有り学習データセットによる推定では, ネットワークのノイズ耐性を向上させることができるとわかった。これら数値実験に加え, EMNIST の手書き数字を用いて学習させた, ノイズ有り学習データセットによる ResNet2 に対し, EMNIST の手書きアルファベットをテスト画像¹¹⁰⁾として入力した場合の再構成精度に与える影響を調査した。計測ノイズは 10 dB とした。その結果, NMSE は 0.55 であった。これは, ResNet2 が手書き文字に対して過剰適合を起こしていたことを示しているが, ER 法や HIO 法と匹敵する推定精度であった。

学習枚数が与える推定精度への影響を調査するため, 学習枚数を変えて構築したノイズ有り学習データセットによる ResNet2 の推定精度を Fig. 3.6, Table 3.3 に示す。この結果は, より大量な学習データセットを用いて学習することにより, 推定精度が向上することを示している。さらに, 学習データセットを増やす毎に, ノイズ耐性も向上することが分かった。

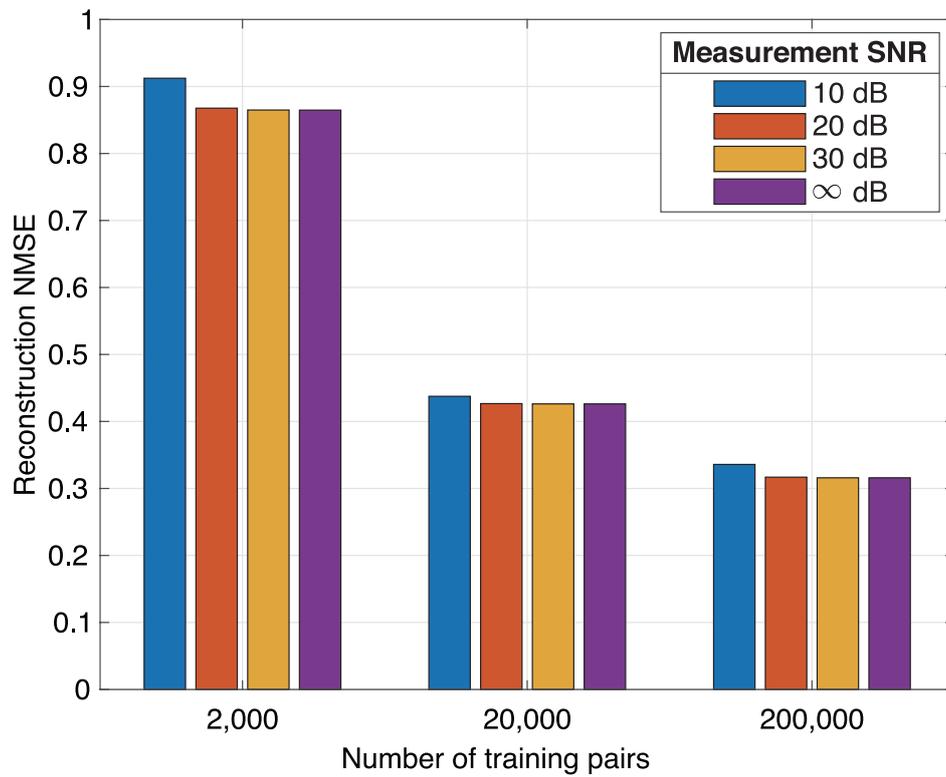


Fig. 3.6 Relationship between the number of training pairs and the NMSE of ResNet2 with the noisy training dataset.

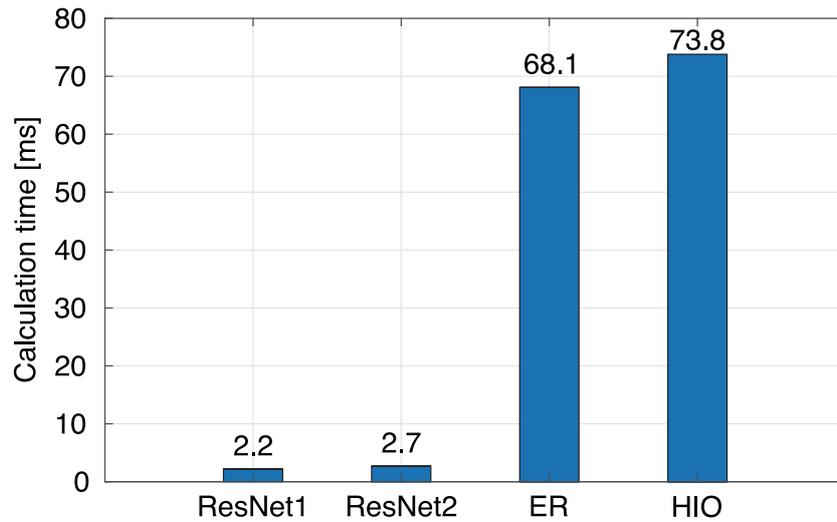


Fig. 3.7 Comparison of the calculation times.

ResNet1, ResNet2, ER 法および HIO 法の計算時間の比較結果を Fig. 3.7 に示す. この結果は, 機械学習による非反復型位相回復手法が従来手法に比べ約 30 倍高速に推定可能であることを示している. ただし, ER 法と HIO 法は CPU による計測結果となっている. ER 法および HIO 法は, データサイズの影響により演算並列度が低くなり GPU による演算では高速な演算を行うことができなかった¹²⁶⁾. 本解析による FFT 演算の場合, CPU を用いた場合は Python の NumPy を使用し約 64 ms, GPU を用いた場合は Python の CuPy を使用し約 579 ms の計算時間を要した.

3.4 結論

数値実験によって, 機械学習による非反復型位相回復手法と反復型位相回復手法の比較をおこなった. 機械学習器として, 畳込みネットワークである ResNet を異なる深さで構築した. 数値実験の結果, より深いネットワーク (ResNet2) はより浅いネットワーク (ResNet1) あるいは従来手法である ER 法や HIO 法よりも高精度に再構成を行うことが出来た. さらに, 学習データセットにノイズを加えて学習器を構築することにより, ノイズ耐性を向上させることに成功した. また, 200,000 枚のような多くの学習枚数を使用することにより, 機械学習ベースの位相回復手法の再構成誤差を低減させることが出来た. これらに加え, 機械学習ベースの非反復型位相回復手法は反復型位相回復手法に比べ 10 倍オーダーで高速な位相推定が可能であることがわかった.

本章において示されたように，深層学習を用いた畳込みネットワークは高精度な再構成，高いノイズ耐性，高速演算性の観点から，位相回復問題に対する有望な手段の一つである．位相回復には長い歴史があり，その適用先にはバイオイメージングや材料科学などの重要な分野が挙げられる．機械学習ベースのアプローチは，高速な位相推定を可能とし，高いノイズ耐性を示すことができることが本研究により示された．位相回復の高い精度，高速性，安定性が求められる様々な分野へ応用が可能である．

第 4 章

機械学習による波面制御の高精度化

4.1 緒論

波面制御は、バイオイメージングや天文学にむけた補償光学のために広く使用されてきた^{96, 97)}。任意の波面を記録・再生する技術として、ホログラフィがある³⁵⁾。ホログラフィでは、コヒーレント光の回折現象，干渉現象をもとに対象の光学情報を記録・再生することができる。参照光と物体光による 2 光波干渉によって，任意の波面を再生するための干渉縞を記録する。この干渉縞には物体光の振幅・位相の両方に関する情報が記録されていることから，干渉縞は全記録を意味するホログラムと呼ばれている。記録されたホログラムに対し，記録時の参照光を照射することによって，記録時の物体光を再生することができる。

任意の波面を生成する別の手法として，所望の物体光が得られるようなホログラムを計算機上で算出する計算機合成ホログラフィ (CGH)¹²⁷⁾ が知られており，3 次元ディスプレイや光ピンセット，ビーム成形などの研究開発が進んでいる^{71, 128-140)}。算出されたホログラムは空間光変調器や回折光学素子を用いて，光波を変調する。

本研究では，図 4.1 (a) に示されるような空間光変調器を可変型ホログラム，図 4.1 (b) に示される回折光学素子 (DOE : Diffractive optical element) を固定型ホログラムと呼ぶ。ホログラムを大別すると，振幅型と位相型の 2 種類の変調方式がある。振幅型の可変型ホログラムには偏光素子付き液晶，デジタルマイクロミラーがある^{141, 142)}。位相型の可変型ホログラムには，液晶やメンブレンミラーなどを利用して光波の位相分布を制御する⁶⁹⁻⁷²⁾。しかし，これらホログラムは光波の振幅あるいは位相のどちらかしか制御出来ないため，所望の波面を高精度に再生することはできない。そのため，可変型ホログラムを複数利用した手法が提案されている^{76, 77)}。しかし，複数の可変型ホログラムの利用に伴い，光学系が高コスト化する。機械学習を利用した非反復型演算による単一ホログラム生成手法も提案なされているが，さらなる高精度化には複数のホログラムを利用する必要

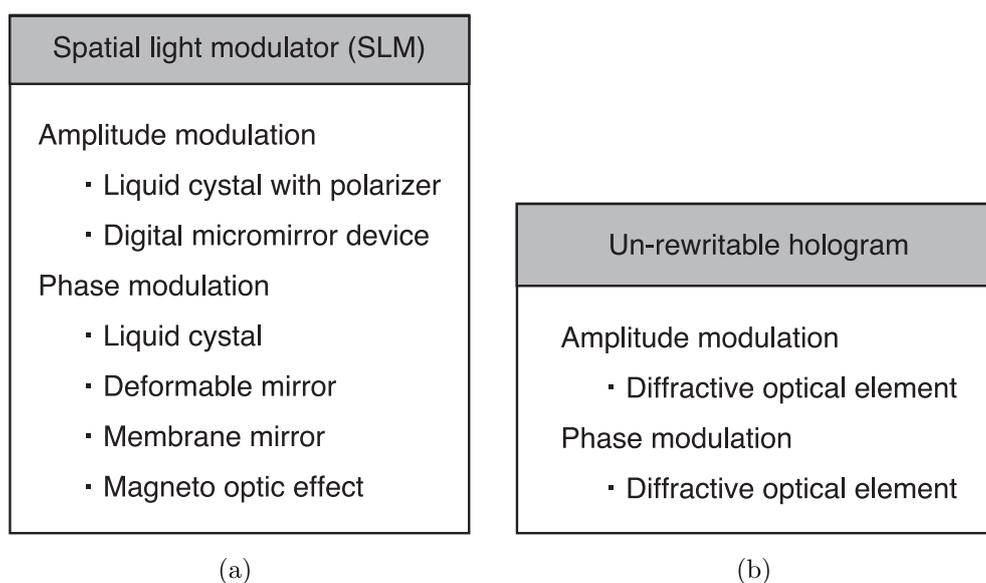


Fig. 4.1 The types of hologram. (a) A rewritable and (b) an un-rewritable.

がある³¹⁾。

一方、可変型ホログラムと固定型ホログラムを利用することにより、3次元ディスプレイ、ヘッドマウントディスプレイ、光学分類器において性能向上が図られている⁷⁹⁻⁸³⁾。

本研究では、複数の可変型ホログラムの利用に伴う高コスト化の課題を緩和・解消するべく、波面制御に機械学習を導入し、可変型ホログラム1つと固定型ホログラム1つを組み合わせてCGHにおける再生波面の精度向上を図る。固定型ホログラムの設計には、再生対象が所属する集合を含むデータベースを用い、設計光波と所望光波の誤差を最小化するように学習を行う。固定型ホログラムの学習完了後、可変型ホログラムの設計を行う。2つのホログラムを利用することによる波面の表現力向上に加え、低コストな導入が可能な固定型ホログラムをデータベースに基づき学習することによって、コストパフォーマンスに優れた再生を行うことができる。

本章では波面の再生精度向上を目的に、可変型ホログラム1つと固定型ホログラム1つを用いた機械学習を導入した波面制御手法を提案する。4.2節では単一の可変型ホログラムにおける設計技術について述べる。4.3節では、提案手法におけるホログラム設計手法について述べる。4.4節では、数値実験結果について述べる。4.5節では、数値実験結果についての考察を述べる。

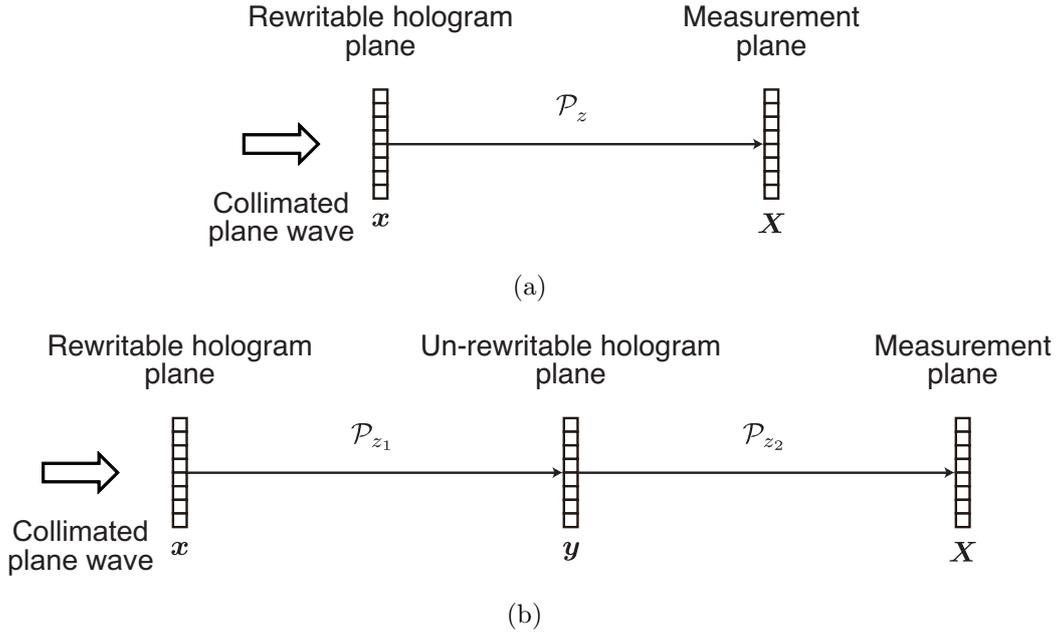


Fig. 4.2 Flow of regeneration. (a) A single rewritable hologram and (b) a single rewritable hologram and un-rewritable hologram.

4.2 単一の可変型ホログラムによる波面制御

本研究では可変型ホログラムの単一利用による波面再生を比較対象とする．可変型ホログラムの単一利用による再生は，Fig. 4.2 (a) に示す光学系を仮定する．可変型ホログラムは位相型，振幅型の2種類，量子化深さは1ビット，8ビットの合計4種類とする．再生される強度画像 I は，

$$I = |\mathbf{X}|^2 = |\mathcal{P}_z[\mathbf{x}]|^2, \quad (4.1)$$

とあらわすことができる．ここで， \mathbf{X} はホログラムからイメージセンサまで伝搬される波面， \mathbf{x} は可変型ホログラムに表示されるパターン， $\mathcal{P}_z[\bullet]$ は可変型ホログラムから距離 z 離れた場所におけるフレネル回折伝搬演算子を示している．ホログラムの設計は，Fig. 4.3 に示す Gerchberg Saxton 法をベースとした誤差逆伝播法を用いた反復演算学習にしたがって行う¹⁴³⁾．

可変型ホログラムの単一利用の場合，ホログラム生成は次のような反復プロセスとなる．

- (1-1) ホログラムの初期値 \mathbf{x}_n を $\mathbf{x}_n = \mathbf{a}_n \circ \exp(j\phi_n)$ として与える．ここで， \mathbf{a}_n はホログラムの振幅， ϕ_n はホログラムの位相であり，初期値としてランダム値を与える． n は反復回数であり，初期値は1とする．

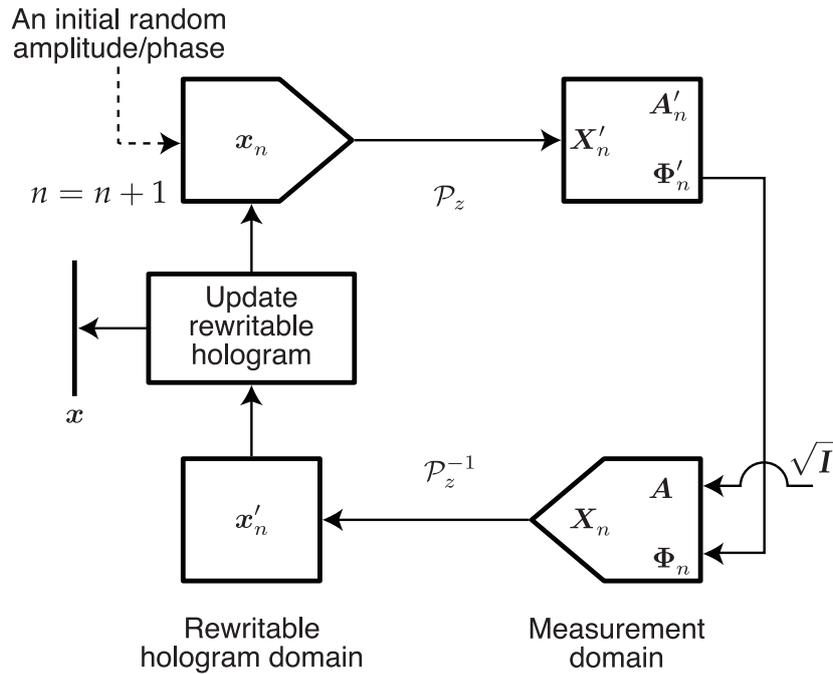


Fig. 4.3 Flow of designing a single rewritable hologram.

- (1-2) 中間推定される計測面での波面 \mathbf{X}'_n は $\mathbf{X}'_n = \mathcal{P}_z[\mathbf{x}_n] = \mathbf{A}'_n \circ \exp(j\Phi'_n)$ となる。ここで、 \mathbf{A}'_n は中間推定される再生波面の振幅、 Φ'_n は中間推定される再生波面の位相である。
- (1-3) 計測面の振幅を \sqrt{I} へと置換し、推定再生波面 \mathbf{X}_n へと更新する。
- (1-4) 中間推定されるホログラム \mathbf{x}'_n は $\mathbf{x}'_n = \mathcal{P}_z^{-1}[\mathbf{X}_n]$ とあらわす。ここで、 \mathcal{P}_z^{-1} は距離 z 離れた場所への逆フレネル回折伝搬演算子である。
- (1-5) ホログラムに対して、regularized PIE (rPIE) アルゴリズム¹⁴⁴⁾による更新式を適用後、振幅拘束あるいは位相拘束が適用され、 \mathbf{x}_n となり、 n を1だけ増加する。更新式は後述する。

ステップ (1-2) - (1-5) は指定回数だけ反復する。

ホログラムあるいはホログラムへの入射波面の更新には、rPIE アルゴリズムによる更新式を適用する。rPIE アルゴリズムは、ホログラムあるいはホログラムへの入射波面の更新に利用され、対象とする波面からの順伝播と逆伝播時の波面を使用した最急降下法によって精度と収束速度を向上させる。同時に更新速度を高めるためのパラメータも導入され

ている。rPIE アルゴリズムは従来手法と提案手法共に再生精度向上が期待される。rPIE アルゴリズムの更新式は、

$$\hat{\mathbf{b}} = \mathbf{b} + \frac{\mathbf{c}^* \circ (\mathbf{d}' - \mathbf{d})}{(1 - \alpha)|\mathbf{c}|^2 + \alpha(|\mathbf{c}|_{\max})^2}, \quad (4.2)$$

とあらわされる。ここで \mathbf{b} は更新前のホログラムあるいは更新前の入射波面、 $\hat{\mathbf{b}}$ は更新結果である。 \mathbf{c} は \mathbf{b} がホログラムの場合に順伝搬時のホログラムへの入射波面を示し、 \mathbf{b} が入射波面の場合は順伝搬時のホログラムをあらわす。 $*$ は複素共役演算子、 \mathbf{d} は順伝搬時のホログラムからの射出波面、 \mathbf{d}' は逆伝搬時のホログラムからの射出波面、 α は更新係数をあらわす。rPIE アルゴリズムによるホログラムの更新後、振幅型ホログラムの場合、

$$\hat{x}_a(x, y) = |\hat{x}(x, y)|, \quad (4.3)$$

により拘束を適用する。ここで $\hat{x}_a(x, y)$ は拘束条件付与後のホログラムの振幅、 $\hat{x}(x, y)$ は rPIE アルゴリズム適用後のホログラムを示す。 $|\bullet|$ は要素ごとの振幅抽出演算子である。位相型ホログラムの場合は、

$$\hat{x}_p(x, y) = \hat{a}_x \exp(j\hat{\phi}(x, y)), \quad (4.4)$$

$$\hat{a}_x = \frac{1}{N_x N_y} \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} |\hat{x}(i, j)|, \quad (4.5)$$

により拘束を適用する。ここで $\hat{x}_p(x, y)$ は拘束条件付与後のホログラムの位相、 \hat{a}_x はホログラムへ入射される光波の平均振幅、 $\hat{\phi}(x, y)$ は rPIE アルゴリズム適用後のホログラムの位相、 N_x , N_y はそれぞれホログラムの x 方向、 y 方向の画素数を示す。

また、反復回数が $n/2$ を超えてから、ホログラムは1ビットあるいは8ビット量子化を実施する。急峻に量子化を行うことは、学習の連続性が損なわれ、学習の進展を阻害する。したがって1ビット量子化には段階的量子化を適用する。段階的1ビット量子化は振幅型 CGH の場合、

$$\hat{x}_a(x, y) = \begin{cases} (\hat{\mathbf{x}}_a)_{\max}, & \left(\hat{x}_a(x, y) \geq \left(1 - \frac{q(n)}{2}\right)(\hat{\mathbf{x}}_a)_{\max} \right), \\ \hat{x}_a(x, y), & \left(\frac{q(n)(\hat{\mathbf{x}}_a)_{\max}}{2} \leq \hat{x}_a(x, y) < \left(1 - \frac{q(n)}{2}\right)(\hat{\mathbf{x}}_a)_{\max} \right), \\ 0, & \left(\hat{x}_a(x, y) < \frac{q(n)(\hat{\mathbf{x}}_a)_{\max}}{2} \right), \end{cases} \quad (4.6)$$

となる。その後、

$$\hat{x}_a(x, y) = \begin{cases} 1 & (\hat{x}_a(x, y) \geq 1), \\ \hat{x}_a(x, y) & (\hat{x}_a(x, y) < 1), \end{cases} \quad (4.7)$$

を適用する。同様に、位相型ホログラムの段階的1ビット量子化は、

$$\hat{\phi}(x, y) = \begin{cases} \pi, & \left(|\hat{\phi}(x, y)| \geq \left(1 - \frac{q(n)}{2}\right) \pi \right), \\ \hat{\phi}(x, y), & \left(\frac{q(n)\pi}{2} \leq |\hat{\phi}(x, y)| < \left(1 - \frac{q(n)}{2}\right) \pi \right), \\ 0, & \left(0 \leq |\hat{\phi}(x, y)| < \frac{q(n)\pi}{2} \right), \end{cases} \quad (4.8)$$

となる。ここで、 $q(n)$ は段階的量子化のためのパラメータであり、

$$q(n) = \begin{cases} 0, & \left(n \leq \frac{N}{2} \right), \\ \frac{4}{N} \left(n - \frac{N}{2} \right), & \left(\frac{N}{2} < n < \frac{3N}{4} \right), \\ 1, & \left(n \geq \frac{3N}{4} \right), \end{cases} \quad (4.9)$$

とあらわされる。ここで n は反復回数、 N は総反復回数であり、 $n = N/2 \sim 3N/4$ の間で徐々に量子化が行われる。また、8ビット量子化の場合は、振幅型ホログラムでは上限を1として $0 \leq \hat{x}_a(x, y) \leq 1$ の範囲で、位相型ホログラムの場合は、 $-\pi < \hat{\phi}(x, y) \leq \pi$ の範囲で量子化をおこなった。

4.3 可変型ホログラムと固定型ホログラムによる波面制御の高精度化

可変型ホログラム1つと固定型ホログラム1つを組み合わせた波面の再生精度向上は、Fig. 4.2 (b) に示す光学系を仮定する。2つのホログラムを利用することによる波面の表現力向上に加え、低コストな導入が可能な固定型ホログラムをデータベースに基づき学習することによって、コストパフォーマンスに優れた再生を実現させる。ここで、学習される固定型ホログラムをデータベース適合化ホログラムと呼ぶ。また、データベース適合化ホログラムはそれぞれ位相型、振幅型を1ビット、8ビットで設計し、合計4種類を検討する。ただし、固定型の振幅ホログラムは透過・不透過の1ビットでしか実装できないが、本数値実験では位相型ホログラムとの解析と対応させるため、8ビットも検討した。

再生される強度画像 I は、

$$I = |\mathbf{X}|^2 = |\mathcal{P}_{z_2} [\mathcal{P}_{z_1} [\mathbf{x}] \circ \mathbf{y}]|^2, \quad (4.10)$$

とあらわすことができる。ここで、 \mathbf{x} は可変型ホログラムに表示されるパターン、 \mathbf{y} はデータベース適合化ホログラムのパターン、 $\mathcal{P}_{z_1}[\bullet]$ は可変型ホログラムから距離 z_1 離れた場所

におけるフレネル回折伝搬演算, $\mathcal{P}_{z_2}[\bullet]$ はデータベース適合化ホログラムから距離 z_2 離れた場所におけるフレネル回折伝搬演算を示している. 提案手法では, 再生対象が所属する集合を含むデータベースに基づく学習を行う. データベース適合化ホログラムの学習および可変型ホログラムの設計には Fig. 4.4 に示されるようにデータベース適合化ホログラムの学習と, 可変型ホログラムの設計の2段階で行う. データベース適合化ホログラムの学習は, 次のような手順に従っておこなわれる.

- (2-1) 可変型ホログラムの初期値 \mathbf{x}_{mn} を $\mathbf{x}_{mn} = \mathbf{a}_{mn} \circ \exp(j\phi_{mn})$ として与える. ここで, \mathbf{x}_{mn} , \mathbf{a}_{mn} , ϕ_{mn} はそれぞれ可変型ホログラム面における学習画像 m 枚目の n 回反復時の波面, 振幅, 位相である. ここで, 振幅ホログラムの場合の初期値は1, 位相ホログラムの場合の初期値は0を与える. 反復回数 n の初期値は1とする.
- (2-2) データベース適合化ホログラムによる変調を受けた後, 中間推定される計測面での波面 \mathbf{X}'_{mn} は $\mathbf{X}'_{mn} = \mathcal{P}_{z_2}[\mathcal{P}_{z_1}[\mathbf{x}_{mn}] \circ \mathbf{y}_n] = \mathbf{A}'_{mn} \circ \exp(j\Phi'_{mn})$ となる. ここで, \mathbf{y}_n は n 回反復時のデータベース適合化ホログラムの波面であり, 振幅ホログラムの場合の初期振幅は1, 位相ホログラムの場合の初期位相は0を与える. \mathbf{A}'_{mn} , Φ'_{mn} はそれぞれ計測面において中間推定される再生波面の振幅, 位相である.
- (2-3) 計測面の振幅を対応するデータベースの振幅 $\sqrt{I_m}$ へと置換し, 推定再生波面 \mathbf{X}_{mn} へと更新する.
- (2-4) データベース適合化ホログラム \mathbf{y}'_{mn} は $\mathbf{y}'_{mn} = \mathcal{P}_{z_2}^{-1}[\mathbf{X}_{mn}]$ となる. その後, 式 (4.2) の rPIE アルゴリズムによりデータベース適合化ホログラムおよびデータベース適合化ホログラムへ入射される波面を更新する.
- (2-5) 更新されたデータベース適合化ホログラムは学習画像枚数 M で平均化され, 次の反復計算時におけるデータベース適合化ホログラムである \mathbf{y}_{n+1} となる. 更新された入射波面を用いて距離 z_1 だけ逆フレネル回折演算をおこない, 中間推定される可変型ホログラム面の波面 \mathbf{x}'_{mn} を得る.
- (2-6) 中間推定された可変型ホログラムに対し, 振幅あるいは位相拘束を適用し \mathbf{x}_{mn} を得る. n を1だけ増加する.

ステップ (2-2) - (2-6) は指定回数だけ反復する.

データベース適合化ホログラムの学習後, 可変型ホログラムの設計を行う. その手順は以下の通りである.

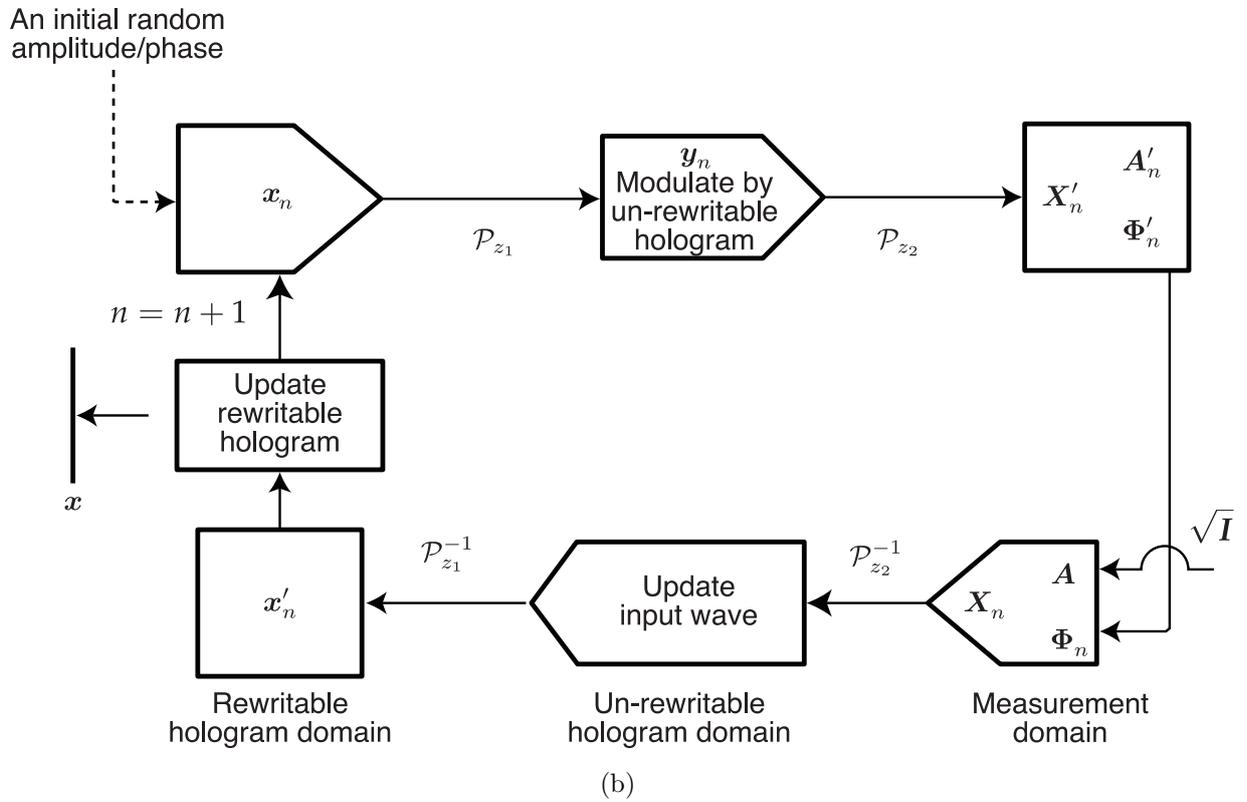
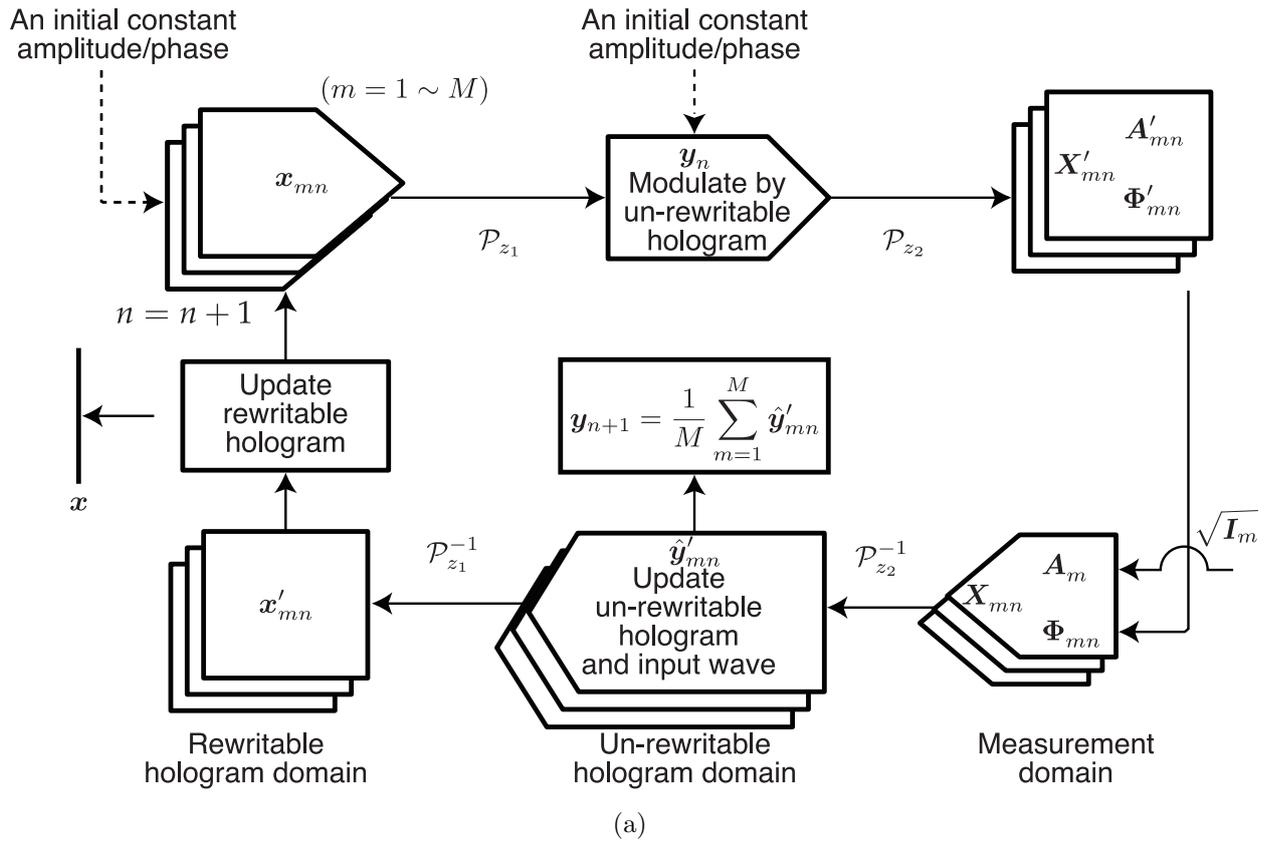


Fig. 4.4 Flow of the proposed method. (a) Optimization stage of the un-rewritable hologram and (b) design stage of the rewritable hologram.

- (3-1) 可変型ホログラムの初期値 \mathbf{x}_n を $\mathbf{x}_n = \mathbf{a}_n \circ \exp(j\phi_n)$ として与える。ここで、 \mathbf{a}_n は CGH 面での振幅、 ϕ_n は CGH 面での位相であり、初期値としてランダム値を与える。 n は反復回数であり、初期値は 1 とする。
- (3-2) データベースに適合化された固定型ホログラムの \mathbf{y} による変調を受けた後、中間推定される計測面での波面 \mathbf{X}'_n は $\mathbf{X}'_n = \mathcal{P}_{z_2}[\mathcal{P}_{z_1}[\mathbf{x}_n] \circ \mathbf{y}] = \mathbf{A}'_n \circ \exp(j\Phi'_n)$ となる。ここで、 \mathbf{A}'_n 、 ϕ'_n はそれぞれ計測面において中間推定される再生波面の振幅、位相である。
- (3-3) 計測面の振幅を \sqrt{I} へと置換し、推定再生波面 \mathbf{X}_n へと更新し、固定型ホログラムまで距離 z_2 だけ逆フレネル回折演算する。
- (3-4) 逆フレネル回折演算時における固定型ホログラムへの入射波面は式 (4.2) の rPIE アルゴリズムにより更新する。
- (3-5) 更新された入射波面を用いて距離 z_1 だけ逆フレネル回折演算をおこない、中間推定される可変型ホログラムの波面 \mathbf{x}'_n を得る。
- (3-6) 中間推定された可変型ホログラムに対し、振幅あるいは位相拘束を適用し \mathbf{x}_n を得る。 n を 1 だけ増加する。

ステップ (3-2) - (3-6) は指定回数だけ反復する。

4.4 数値実験

計算機による数値実験を実施した。フレネル回折伝搬距離 z , z_1 , z_2 はいずれも 50 mm とした。使用波長は 532 nm とした。所望の波面として用いる画像は、Fig. 2.9 に示す EMNIST データベースからランダムに取得した手書き数字を利用した¹¹⁰⁾。原画像よりも大きな 64×64 の領域中央に 28×28 の原画像を配置し、再生像とその周辺に与える影響を調査した。rPIE アルゴリズムの更新係数 α は 0.1 とした。提案手法で使用する学習データセットは 1,000 枚、学習に要する反復回数は 500 とした。テストデータセットは 100 枚とした。なお学習データセットとテストデータセットは重複はしていない。テストデータセットを用いた可変型ホログラムの設計に要する反復回数は 300 とした。本数値実験は全て Python により実装した。実行環境は CPU : Intel Xeon 6134 CPU 3.2 GHz, RAM : 192 GB である。

再生精度の定量評価に二乗平均平方根誤差 (RMSE : Root mean squared error) を使用した³¹⁾。RMSE は

$$\text{RMSE} = \sqrt{\frac{1}{N_x N_y} \sum_{x=1}^{N_x} \sum_{y=1}^{N_y} \left(X_a(x, y) - \hat{X}_a(x, y) \right)^2}, \quad (4.11)$$

とあらわされる。ここで、再生する波面は振幅物体と仮定し、 X_a は所望の波面の振幅、 \hat{X}_a は推定波面の振幅をあらわす。テストデータ全体の平均 RMSE にて再生精度の評価を行う。

4.4.1 1ビット振幅可変型ホログラムと固定型ホログラムによる波面制御

所望の波面として用いたテスト画像例を Fig. 4.5 に示す。可変型ホログラムに1ビット振幅を用いた結果を Fig. 4.6, 再生精度の平均値を Fig. 4.7 にそれぞれ示す。単一の1ビット振幅可変型ホログラムの場合、再生像のコントラストが低く、所望の再生像周辺にアーティファクトが確認できる。振幅のデータベース適合化ホログラムを使用した場合は、コントラストが改善し、アーティファクトが低減され再生精度が向上することがわかった。しかし、位相のデータベース適合化ホログラムを使用した場合は、改善効果を確認することが出来なかった。

4.4.2 8ビット振幅可変型ホログラムと固定型ホログラムによる波面制御

可変型ホログラムに8ビット振幅を用いた結果を Fig. 4.8, 再生精度の平均値を Fig. 4.9 にそれぞれ示す。単一の1ビット振幅可変型ホログラムの場合、再生像の鮮鋭度が低く、コントラストも低く、所望の再生像周辺にアーティファクトが確認できる。振幅のデータベース適合化ホログラムおよび8ビットの位相のデータベース適合化ホログラムを使用した場合は、鮮鋭度の向上、コントラストの上昇や、アーティファクトの低減により再生精度が向上することがわかった。しかし、1ビット位相のデータベース適合化ホログラムを使用した場合は、改善効果を確認することが出来なかった。

4.4.3 1ビット位相可変型ホログラムと固定型ホログラムによる波面制御

可変型ホログラムに1ビット位相を用いた結果を Fig. 4.10, 再生精度の平均値を Fig. 4.11 にそれぞれ示す。単一の1ビット位相可変型ホログラムの場合、再生像のコントラストが低いことが確認できる。データベース適合化ホログラムを使用した場合は、全ての条件

においてコントラストの上昇や、アーティファクトの低減により再生精度が向上することがわかった。

4.4.4 8ビット位相可変型ホログラムと固定型ホログラムによる波面制御

可変型ホログラムに8ビット位相を用いた結果を Fig. 4.12, 再生精度の平均値を Fig. 4.13 にそれぞれ示す。単一の8ビット位相可変型ホログラムの場合、再生像のコントラストが低いことや、再生像周辺のアーティファクトが確認できる。データベース適合化ホログラムを使用した場合では、全ての条件においてコントラストの上昇や、アーティファクトの低減により再生精度が向上することがわかった。

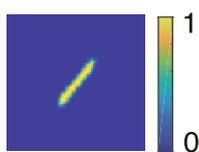


Fig. 4.5 An example of target image.

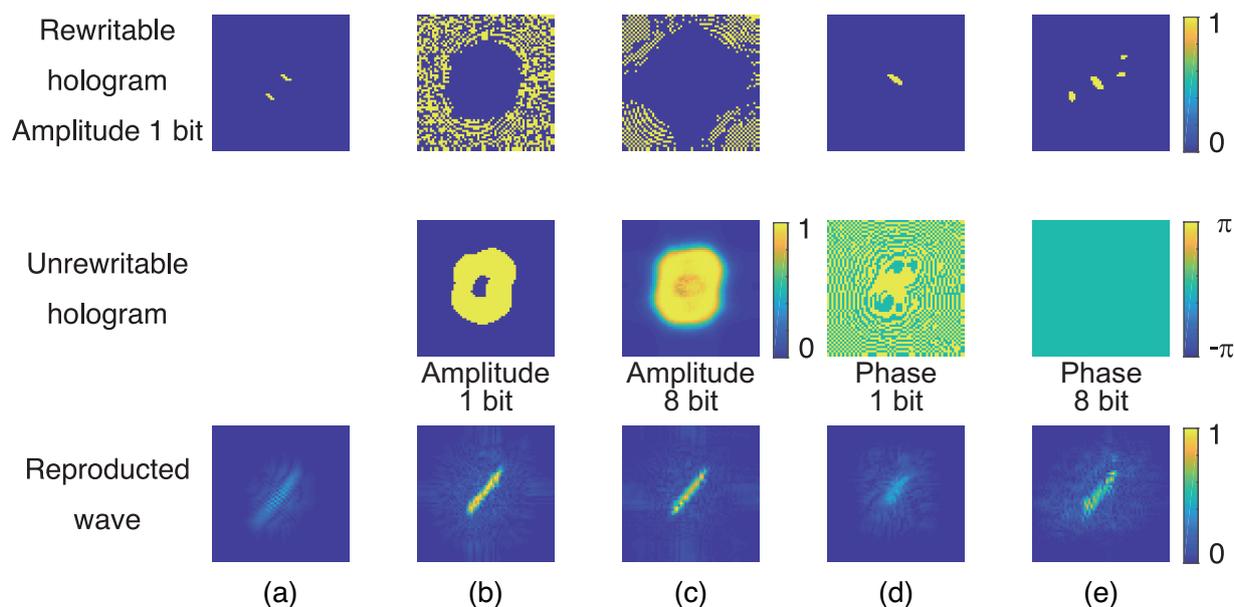


Fig. 4.6 Analysis results. (a) Rewritable 1 bit amplitude hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

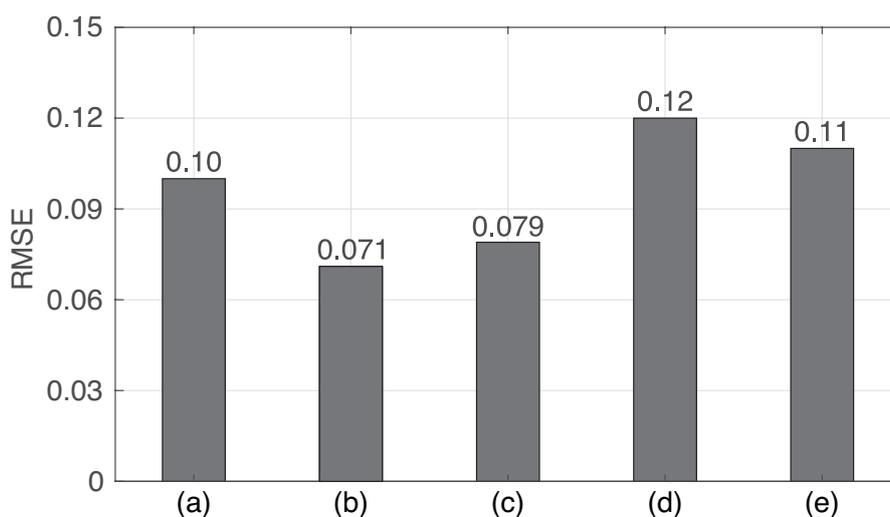


Fig. 4.7 Reproduction error. (a) Rewritable 1 bit amplitude hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

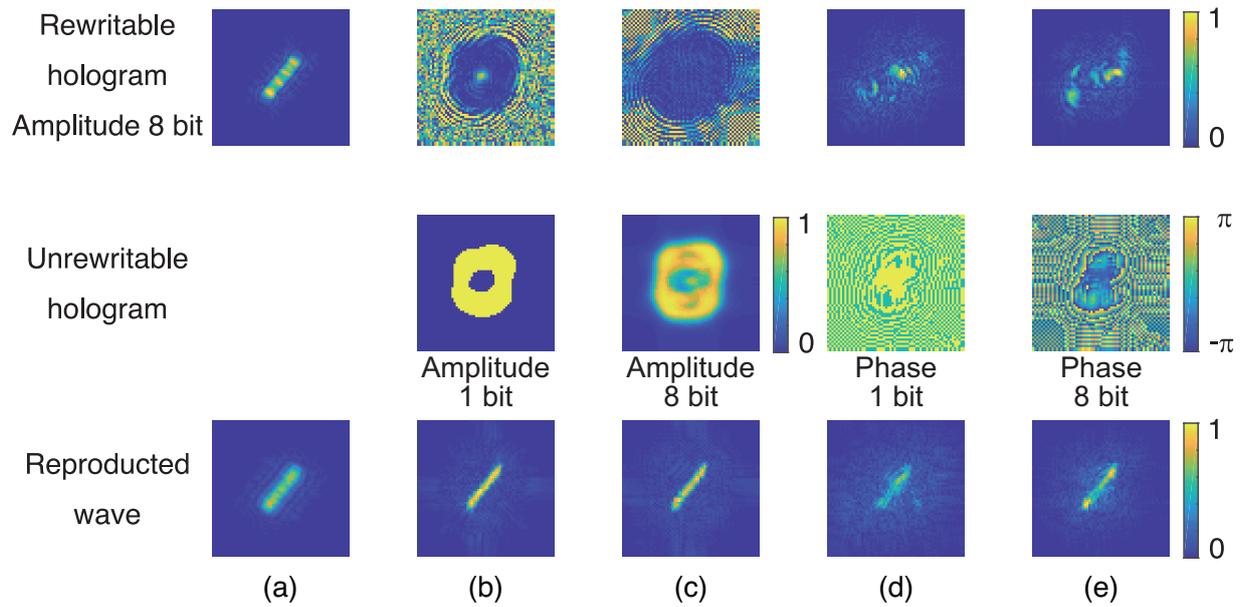


Fig. 4.8 Analysis results. (a) Rewritable 8 bit amplitude hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

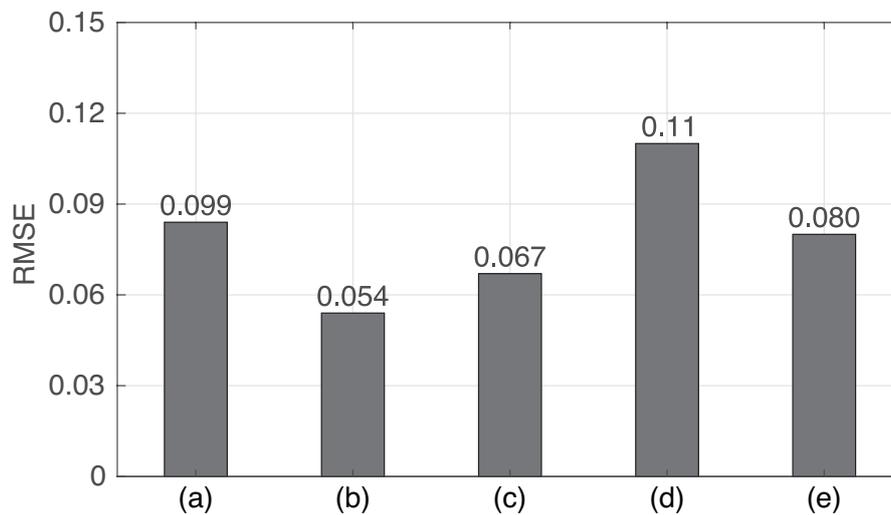


Fig. 4.9 Reproduction error. (a) Rewritable 8 bit amplitude hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

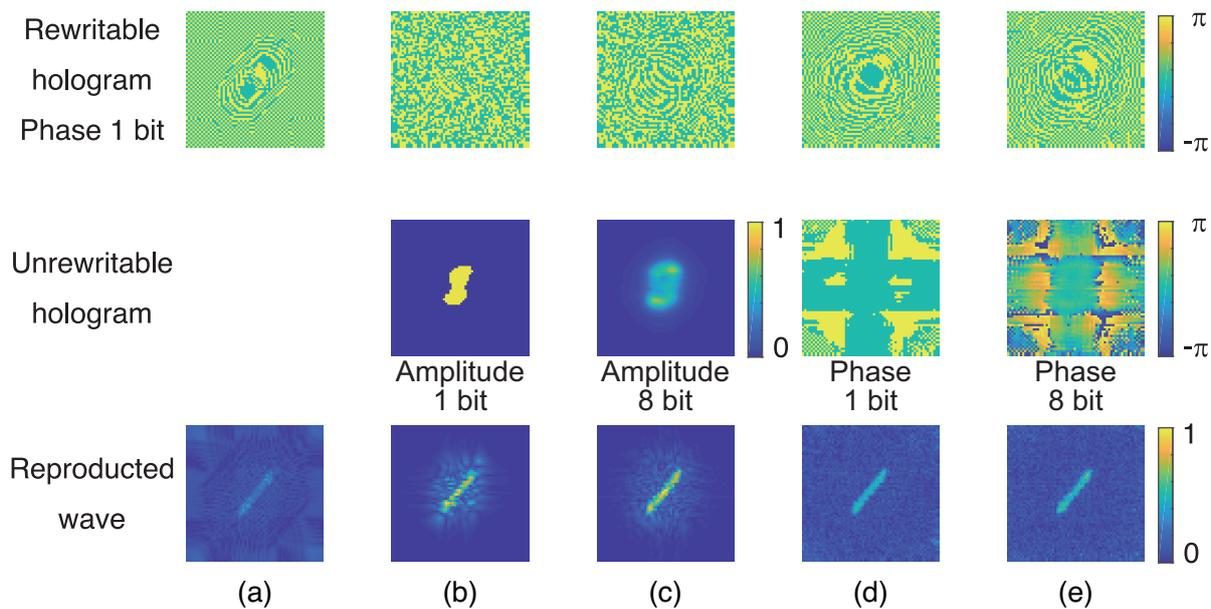


Fig. 4.10 Analysis results. (a) Rewritable 1 bit phase hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

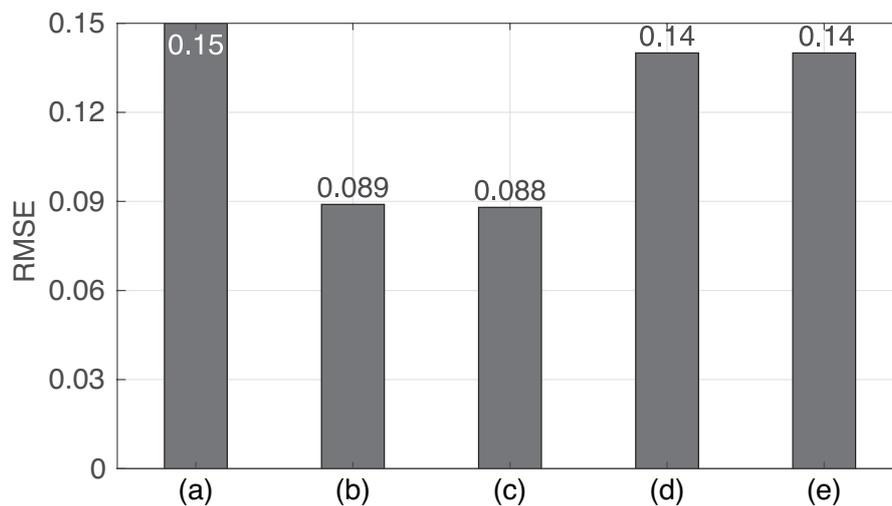


Fig. 4.11 Reproduction error. (a) Rewritable 1 bit phase hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

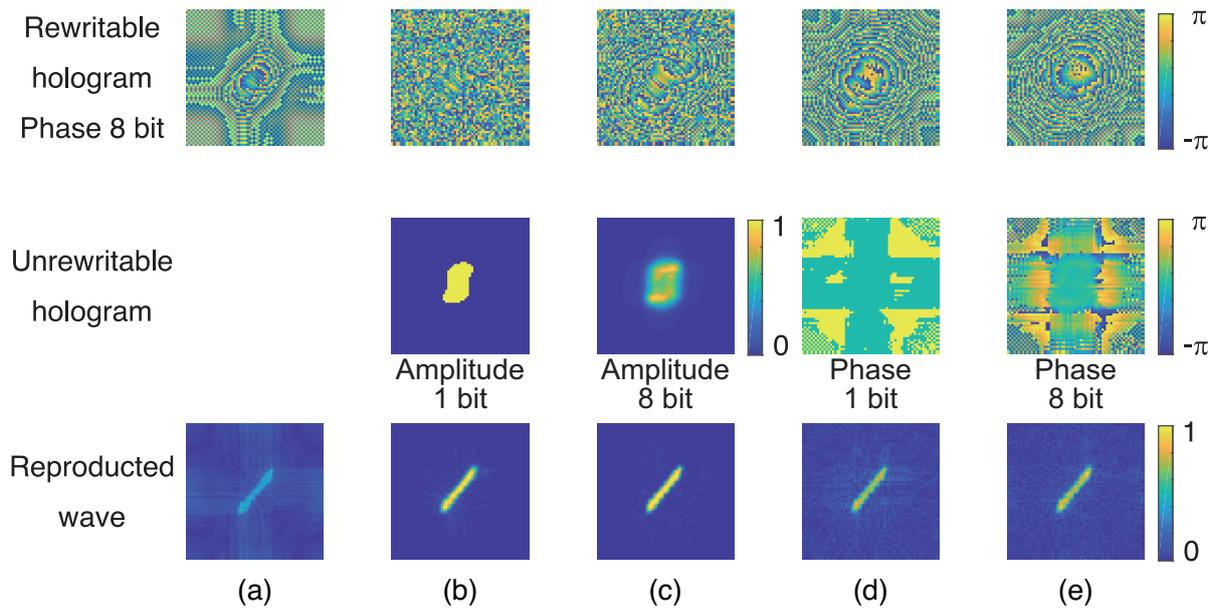


Fig. 4.12 Analysis results. (a) Rewritable 8 bit phase hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

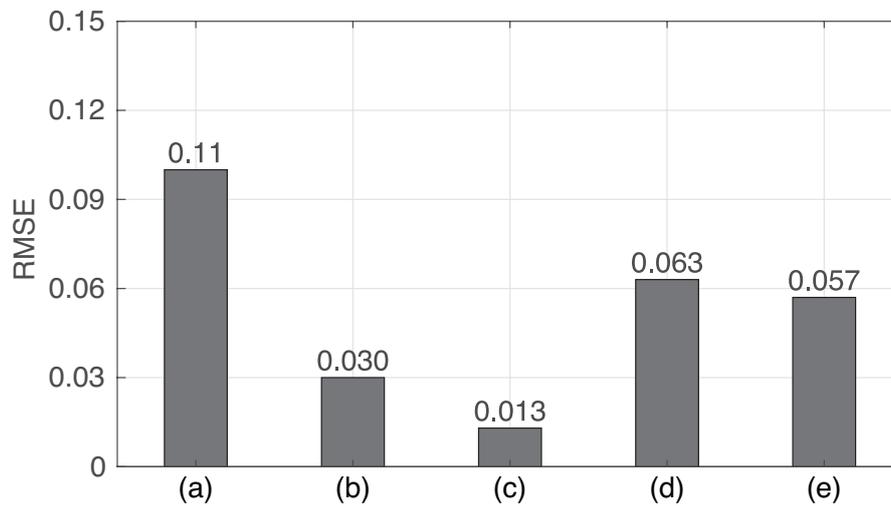


Fig. 4.13 Reproduction error. (a) Rewritable 8 bit phase hologram without additional hologram and (b) with optimized un-rewritable hologram : 1 bit amplitude, (c) 8 bit amplitude, (d) 1 bit phase and (e) 8 bit phase.

Table 4.1 Summary of the accuracies (RMSEs) of the reproduced wave in the numerical analyses.

		A single rewritable hologram	With optimized amplitude hologram		With optimized phase hologram	
			1 bit	8 bit	1 bit	8 bit
Amplitude hologram	1 bit	0.10	0.071	0.079	0.12	0.11
	8 bit	0.099	0.054	0.067	0.11	0.080
Phase hologram	1 bit	0.15	0.089	0.088	0.14	0.14
	8 bit	0.11	0.030	0.013	0.063	0.057

4.4.5 考察

4.4.1 項から 4.4.4 項で示した RMSE の一覧を Table. 4.1 に示す. Table. 4.1 に示されるように, 単一の可変型ホログラムでの再生に比べ, 多くのケースで学習された固定型ホログラムを追加して再生する提案手法は, 再生精度が向上することがわかった. 中でも, 位相 8 ビットの可変型ホログラムに対して学習された 1 ビットおよび 8 ビットの固定型振幅ホログラムを追加することにより, コントラストの向上やアーティファクトの低減などの点において他手法に比べ大きく再生品質を向上させることが出来た. これは, 再生対象が所属するデータベースに基づいて学習された固定型振幅ホログラムによって再生に必要な光波へ効果的に変調できたことを示している. 一方, 振幅 1 ビットの可変ホログラムに対して学習された 1 ビットおよび 8 ビットの固定型位相ホログラムおよび, 振幅 8 ビットのホログラムに対して学習された 1 ビットの固定型位相ホログラムでは再生精度を向上させることができなかった. これら組み合わせの場合では, 学習されたホログラムが, 再生に必要な光波が効果的に変調できなかったことを示している.

再生対象による再生品質の違いをみるために, 再生対象を変えた再生結果を比較する. 単一の 8 ビット位相可変型ホログラムによる再生結果を Fig. 4.14, 良好な再生であった 8 ビット位相可変型ホログラムに固定型ホログラムとして 1 ビット位相型ホログラムを利用した再生結果を Fig. 4.15 にそれぞれ示す. Fig. 4.14 からわかるように再生対象の線の太さにより, コントラストやアーティファクトの強さが変化していることがわかる. また単一のホログラムによる変調のため, ホログラムの変調能力が低く, エイリアジングが発生していることがわかる. 一方, Fig. 4.15 では, 複数のホログラムを使用したことにより, 変調の表現力を高められ, ホログラムのエイリアジングが解消された. この結果, 再生対象に依存することなく, 再生品質が向上できた.

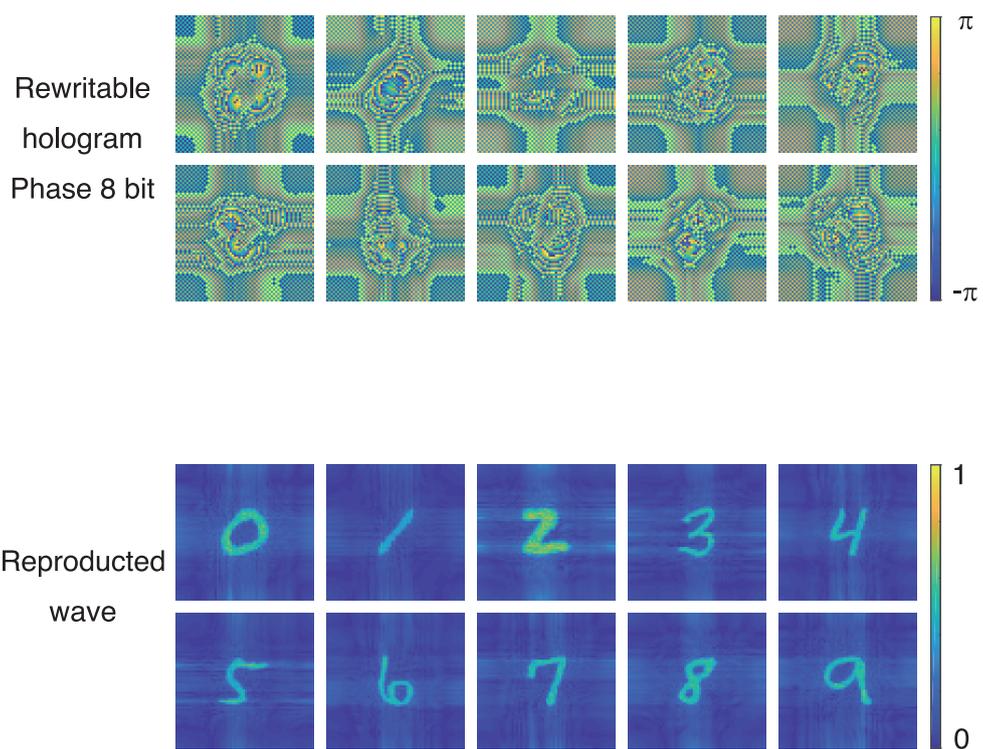


Fig. 4.14 Analysis results using rewritable 8 bit phase hologram without additional hologram.

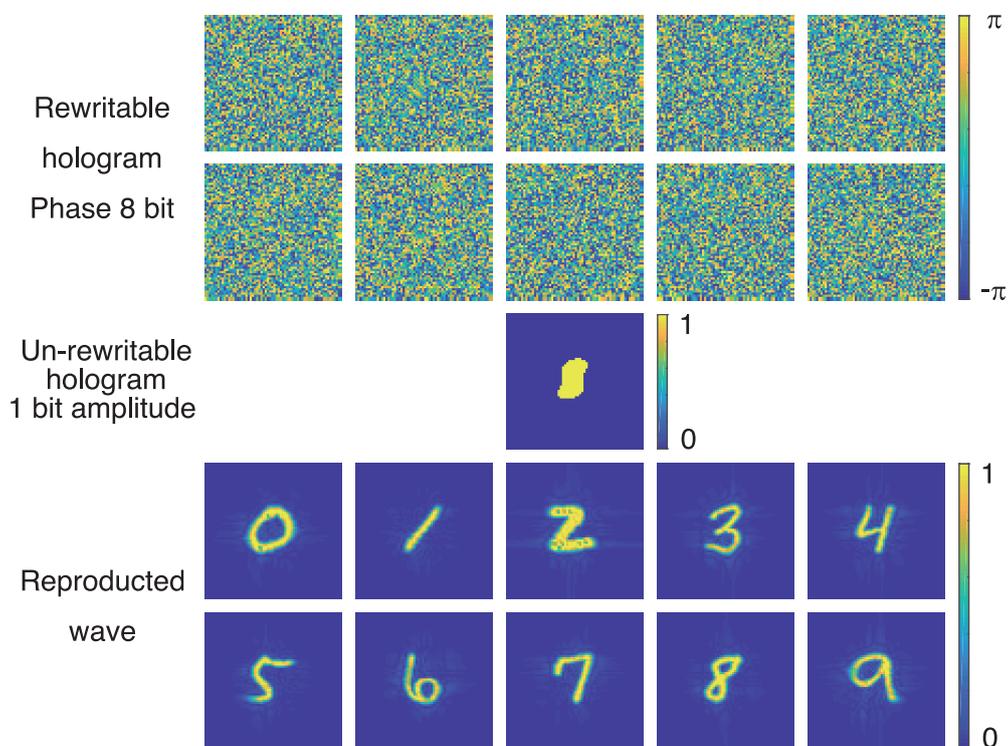


Fig. 4.15 Analysis results using rewritable 8 bit phase hologram with optimized un-rewritable 1 bit amplitude hologram.

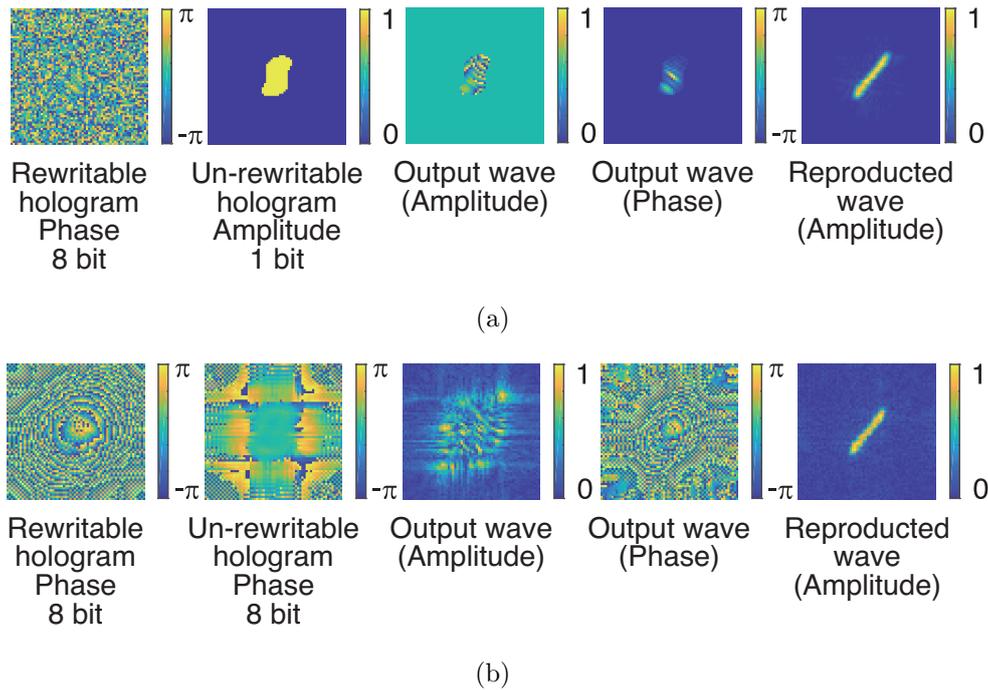


Fig. 4.16 Output wave from un-rewritable hologram using rewritable 8 bit phase hologram with optimized un-rewritable (a) 1 bit amplitude hologram and (b) 8 bit phase hologram.

Fig. 4.16 に学習された固定型ホログラムおよびその固定型ホログラムからの出射光の振る舞いの一例を示す。Fig. 4.16 (a) に示されるように、固定型振幅ホログラムによる変調の場合、出射光は振幅ホログラムにより領域制限されて変調され、限定領域のみ値をもつ光波となり、伝搬されたことがわかる。出射光の位相はエイリアジングがない波面となっていることがわかる。また、Fig. 4.16 (b) に示されるように、固定型位相ホログラムによる変調の場合、位相の折返しを伴う変調を受け、伝搬されたことがわかる。しかし、出射光の位相は Fig. 4.16 (a) とは異なり、わずかにエイリアジングが生じていることがわかる。以上のことから、位相可変型ホログラムと振幅固定型ホログラムによる波面生成では、最も効率的な波面変調が行われ、高品質な再生を実現できたといえる。

4.5 結論

本章では、複数の可変型ホログラムの利用に伴う高コスト化の課題を緩和・解消するべく、可変型ホログラム1つと固定型ホログラム1つを組み合わせる再生波面の精度向上を図る手法を示した。1ビット、8ビットの量子化深さの振幅、位相の可変型ホログラムに

対し、それぞれ1ビット、8ビットの量子化深さの学習された固定型の振幅、位相ホログラムを追加した。その結果、多くのケースで単一の可変型ホログラムよりもコントラストが高く、アーティファクトを低減させた再生精度の高い再生像を得ることができた。特に、位相8ビットの可変型ホログラムに対して学習された1ビットおよび8ビットの固定型振幅ホログラムでは、コントラストの向上やアーティファクトの低減などの点においてそれぞれ約3.7倍、8.5倍の再生品質向上に成功した。

一方、提案手法では反復演算を要する、あるいは光学素子が増加する問題が生じる。しかし、反復演算が必要なのは設計段階のみであり、その後は堀崎らによる手法と組み合わせる事により、高速なホログラムの生成が可能となる³¹⁾。光学系の増加に伴い、精密なアライメントが必要になるため、固定型ホログラムの設置時にはキャリブレーションによる位置合わせが必要になる。これらは、位置決め治具を使用した定位置化や光学系の一体化設計により改善が可能である。

提案手法は、単一の可変型ホログラムによる再生に比べ再生品質を向上させることができ、これまでのように複数の空間光変調器を使用する方法よりも、低コストな光学系を実現することができる。本手法の適用によって低コストかつ小型化可能な補償光学システムが構築でき、バイオイメージングや天文学などの自然科学や3次元ディスプレイなどのエンターテイメントなどに寄与する基盤技術になると期待される。

総括

本研究では、波面計測、波面制御の高度化を図るべく、機械学習を波面計測、波面制御に導入し、性能を改善する手法を考案し、実験的あるいは数値解析で実証した。

1章では、補償光学と構成要素技術である波面計測、波面制御について近年の研究動向と共に整理した。また、機械学習を導入したコンピュータシミュレーションの応用について超解像、定量位相計測およびレンズレスイメージング、低照度下におけるイメージング、散乱イメージングのカテゴリにて解説した。また、本論文の各研究の位置づけ、目的を明確化し概説した。

2章では、単一強度画像から非反復演算による波面計測に成功した。波面計測に対して深層学習を導入することにより、従来までのプリコンディショニングに限らない簡易な光学変調が可能になったことから、波面センサの設計自由度を大幅に拡大させることに成功した。点光源を用いて簡易な光学変調だけでもシングルショット波面計測が実現可能であることを実験実証した。さらに、2次元光源を利用した波面計測についても実験実証をおこなった。

3章では、微弱信号下の位相回復において、ノイズ耐性を向上させた。深いネットワークを用いることにより、浅いネットワークあるいは非反復型位相回復手法よりも高精度に再構成を行うことが示された。また、学習画像に対しノイズを付与して訓練を行った結果、高いノイズ耐性を示す結果を得ることが出来た。そして反復型位相回復手法と機械学習を利用した位相回復手法について数値解析に基づいた比較をおこなった。さらに、非反復型位相回復手法は従来手法に比べ10倍オーダーで高速な推定が行えることを示すことができた。

4章では、可変型ホログラムと固定型ホログラムとの組み合わせによる、コストパフォーマンスに優れた波面制御手法を実証した。複数の可変型ホログラムの利用に伴う高コスト化の課題を緩和・解消するべく、可変型ホログラム1つと固定型ホログラム1つを組み合わせ波面の再生精度向上を図った。固定ホログラムは、対象が所属するデータベースを参考に最適化をおこなった。可変型ホログラムの単一利用による再生に比べ、提案手法で

はコントラストの向上やアーティファクトの低減などの点で再生品質の向上を確認した。ただし、一部の条件では再生品質が低下することも明らかになった。数値解析による定量評価では、再生精度を最大 8.5 倍改善することに成功した。

2次元光源によって示された波面計測の成功事例は、眼底検査における参照光源を不要にする可能性も秘めており、無侵襲検査へ資することになる。さらに、生体バイオイメージングの補償光学に利用される構造化照明そのものを参照光源とすることも原理的には可能であり、様々な分野において設計自由度を拡大させることが可能と考える。

機械学習による波面計測は、設計自由度が拡大されたことにより低コストな波面センサの製造に加え、従来波面センサとの組み合わせにより高精度化へ資する可能性がある。これらは透明試料の計測、レンズアライメント調整、光ピックアップの補正、鏡面反射波面評価、半導体ウェーハや薄膜等のうねり計測など、精密計測分野へ寄与することとなる。

機械学習による位相回復により得られた知見は、高精度高速位相推定への応用が期待される。機械学習の導入による得られる高いノイズ耐性は、これまでノイズを嫌うがために回避していた、積極的なゲイン活用を可能にするため、材料構造解析で利用が見込める。光源の低強度化が期待できるため、従来に比べ低侵襲な解析ができることに加え、装置の低コスト化に資することができる。

機械学習による波面制御では、最適化設計された固定のホログラムを追加するだけで、コントラスト向上やアーティファクト低減などの再生精度を向上させることが可能となる。天体観測におけるデフォーマブルミラーへの追加付与により、コントラストを向上させた波面変調が期待できる。さらに本手法の適用によって低コストかつ小型化可能な波面制御が実現される。対象が含まれるデータセットである必要があるため、用途が限定される3次元ディスプレイやヘッドマウントディスプレイ、光ピンセット、ビーム成形などで利用が見込まれる。

しかし、現在の機械学習は万能ではなく、大量のデータさえあれば優れた結果が得られるわけでない。アプリケーションや利用環境によって、学習を効率的に進め、精度を高めるための適切な光学系を設計する必要がある。本研究における機械学習による波面計測はその代表例であり、機械学習と適切かつ簡便な光学変調との融合は、波面センサの一般化と簡素化に著しく貢献しているといえる。

天体観測、生体医療分野における対象情報の大気揺らぎや生体由来の散乱による劣化を回復させることができる本研究における成果の適用範囲は、これからも拡大が見込まれる。機械学習との融合による卓越した波面計測技術と波面制御技術は、補償光学分野にお

ける次世代要素技術であると言え、高速推定、高精度、ロバストな光計測・制御を実現させる基盤技術となる。本研究によって得られた成果は、光分野を中心とした自然科学の発展に寄与するものと期待される。

謝辞

本研究は大阪大学大学院情報科学研究科情報数学専攻において、本学大学院情報科学研究科谷田純教授のご指導のもとに行ったものである。本研究を遂行するにあたり、終始懇切丁寧なるご指導とご鞭撻を賜りました谷田純教授に深く感謝の意を表すと共に厚く御礼申し上げます。

本学大学院情報科学研究科藤崎泰正教授、沼尾正行教授、小倉裕介准教授には、本論文作成にあたり貴重な御教示を頂きました。ここに深く感謝致します。

本研究を遂行する際に、日夜時間や場所を問わず終始懇切丁寧なる御指導と御助言を頂きました本学大学院情報科学研究科堀崎遼一助教には、心から御礼を申し上げると共に深く感謝致します。

大阪産業技術研究所の齋藤守部長、北口勝久研究主任には大学での研究面、日常業務面、私生活面で温かいご支援やご助言をいただきました。厚く感謝いたします。

和歌山大学システム工学部の野村孝徳教授には大阪大学大学院への転籍に際し、温かいご支援を頂き、光学研究に従事するきっかけを頂きました。厚く御礼申し上げます。

チリの Pontificia Universidad Católica de Valparaíso の Esteban Vera Rojas 准教授には共同研究遂行の上で丁寧なご指導を頂きました。ここに感謝を記します。

研究所への転職や社会人博士への進学に際し、大阪府立大学工業高等専門学校杉浦公彦教授には大変親切にご支援やご助言をいただきました。感謝申し上げます。

前職である大日本印刷株式会社の皆様には、エンジニアとしての基礎を築く上で、丁寧なご指導を受けさせていただきました。深く感謝いたします。

本学博士後期課程の下村優様、博士前期課程の中西哲也様、岡本優花様、井上仁哉様には研究討議や実験推進にあたり多大なるご協力を頂きました。御礼申し上げます。

事務補佐員の松下昌樹子様を含む、共に過ごした谷田研究室の皆様に感謝申し上げます。

日々、労いや励ましの言葉をかけてくださった研究所の皆様や友人に感謝申し上げます。

最後に、日常生活を支えてくださり、社会へ巣立つまで育て上げてくださった両親、家族に心から深く感謝致します。

参考文献

- [1] M. B. Sweatman and A. Coombs: “Decoding european palaeolithic art: extremely ancient knowledge of precession of the equinoxes”, *Athens Journal of History*, **5**, 1, pp. 1–30 (2019).
- [2] J. R. Fienup, J. C. Marron, T. J. Schulz and J. H. Seldin: “Hubble Space Telescope characterized by using phase-retrieval algorithms”, *Applied Optics*, **32**, 10, pp. 1747–1767 (1993).
- [3] H. W. Babcock: “The possibility of compensating astronomical seeing”, *Publications of the Astronomical Society of the Pacific*, **65**, 386, pp. 229–236 (1953).
- [4] J. W. Hardy, J. E. Lefebvre and C. L. Koliopoulos: “Real-time atmospheric compensation”, *Journal of the Optical Society of America*, **67**, 3, pp. 360–369 (1977).
- [5] G. Rousset, J. Fontanella, P. Kern, P. Gigan and F. Rigaut: “First diffraction-limited astronomical images with adaptive optics”, *Advanced Technology Optical Telescopes IV* (Ed. by L. D. Barr), Vol. 1236 *International Society for Optics and Photonics*, SPIE, pp. 193–202 (1990).
- [6] E. J. Fernández, I. Iglesias and P. Artal: “Closed-loop adaptive optics in the human eye”, *Optics Letters*, **26**, 10, pp. 746–748 (2001).
- [7] D. T. Miller, O. P. Kocaoglu, Q. Wang and S. Lee: “Adaptive optics and the eye (super resolution OCT)”, *Eye*, **25**, 3, pp. 321–330 (2011).
- [8] S. Ooto, M. Hangai, K. Takayama, N. Ueda-Arakawa, M. Hanebuchi and N. Yoshimura: “Photoreceptor damage and foveal sensitivity in surgically closed macular holes: an adaptive optics scanning laser ophthalmoscopy study”, *American Journal of Ophthalmology*, **154**, 1, pp. 174–186.e2 (2012).
- [9] M. Miyata, S. Ooto, K. Ogino, N. Gotoh, S. Morooka, Y. Makiyama, T. Hasegawa, M. Sugahara, M. Hata, K. Yamashiro and N. Yoshimura: “Evaluation of photoreceptors in Bietti crystalline dystrophy with CYP4V2 mutations using adaptive op-

- tics scanning laser ophthalmoscopy”, *American Journal of Ophthalmology*, **161**, pp. 196–205.e1 (2016).
- [10] S. A. Burns, A. E. Elsner, K. A. Sapoznik, R. L. Warner and T. J. Gast: “Adaptive optics imaging of the human retina”, *Progress in retinal and eye research*, **68**, 1, pp. 1–30 (2019).
- [11] M. J. Booth: “Adaptive optics in microscopy”, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **365**, 1861, pp. 2829–2843 (2007).
- [12] J. A. Kubby: “Adaptive optics for biological imaging”, CRC Press (2013).
- [13] D. Champelovier, J. Teixeira, J. M. Conan, N. Balla, L. M. Mugnier, T. Tressard, S. Reichinnek, S. Meimon, R. Cossart, H. Rigneault, S. Monneret and A. Malvache: “Image-based adaptive optics for in vivo imaging in the hippocampus”, *Scientific Reports*, **7**, 2, pp. 1–10 (2017).
- [14] T. L. Liu, S. Upadhyayula, D. E. Milkie, V. Singh, K. Wang, I. A. Swinburne, K. R. Mosaliganti, Z. M. Collins, T. W. Hiscock, J. Shea, A. Q. Kohrman, T. N. Medwig, D. Dambournet, R. Forster, B. Cunniff, Y. Ruan, H. Yashiro, S. Scholpp, E. M. Meyerowitz, D. Hockemeyer, D. G. Drubin, B. L. Martin, D. Q. Matus, M. Koyama, S. G. Megason, T. Kirchhausen and E. Betzig: “Observing the cell in its native state: Imaging subcellular dynamics in multicellular organisms”, *Science*, **360**, 6386, pp. 1–13 (2018).
- [15] P. Artal and R. Navarro: “High-resolution imaging of the living human fovea: measurement of the intercenter cone distance by speckle interferometry”, *Optics Letters*, **14**, 20, pp. 1098–1100 (1989).
- [16] T. J. MacGillivray, E. Trucco, J. R. Cameron, B. Dhillon, J. G. Houston and E. J. Van Beek: “Retinal imaging as a source of biomarkers for diagnosis, characterization and prognosis of chronic illness or long-term conditions”, *British Journal of Radiology*, **87**, 6, pp. 1–16 (2014).
- [17] B. C. Chen, W. R. Legant, K. Wang, L. Shao, D. E. Milkie, M. W. Davidson, C. Janetopoulos, X. S. Wu, J. A. Hammer, Z. Liu, B. P. English, Y. Mimori-Kiyosue, D. P. Romero, A. T. Ritter, J. Lippincott-Schwartz, L. Fritz-Laylin, R. D. Mullins, D. M. Mitchell, J. N. Bembenek, A. C. Reymann, R. Böhme, S. W. Grill,

- J. T. Wang, G. Seydoux, U. S. Tulu, D. P. Kiehart and E. Betzig: “Lattice light-sheet microscopy: Imaging molecules to embryos at high spatiotemporal resolution”, *Science*, **346**, 6208, pp. 1–12 (2014).
- [18] F. Rosenblatt: “The perceptron: a probabilistic model for information storage and organization in the brain”, *Psychological Review*, **65**, 6, pp. 386–408 (1958).
- [19] D. E. Rumelhart, G. E. Hinton and R. J. Williams: “Learning representations by back-propagating errors”, *Nature*, **323**, 9, pp. 533–536 (1986).
- [20] X. Glorot, A. Bordes and Y. Bengio: “Deep sparse rectifier neural networks”, *Journal of Machine Learning Research*, **15**, pp. 315–323 (2011).
- [21] Y. Lecun, Y. Bengio and G. Hinton: “Deep learning”, *Nature*, **521**, 7553, pp. 436–444 (2015).
- [22] T. Ando, R. Horisaki and J. Tanida: “Speckle-learning-based object recognition through scattering media”, *Optics Express*, **23**, 26, pp. 33902–33910 (2015).
- [23] R. Takagi, R. Horisaki and J. Tanida: “Object recognition through a multi-mode fiber”, *Optical Review*, **24**, 2, pp. 117–120 (2017).
- [24] H. Chen, Y. Gao, X. Liu and Z. Zhou: “Imaging through scattering media using speckle pattern classification based support vector regression”, *Optics Express*, **26**, 20, pp. 26663–26678 (2018).
- [25] R. Horisaki, R. Takagi and J. Tanida: “Learning-based imaging through scattering media”, *Optics Express*, **24**, 13, pp. 13738–13743 (2016).
- [26] S. Li, M. Deng, J. Lee, A. Sinha and G. Barbastathis: “Imaging through glass diffusers using densely connected convolutional networks”, *Optica*, **5**, 7, pp. 803–813 (2018).
- [27] G. Satat, M. Tancik, O. Gupta, B. Heshmat and R. Raskar: “Object classification through scattering media with deep learning on time resolved measurement”, *Optics Express*, **25**, 15, pp. 17466–17479 (2017).
- [28] A. Sinha, J. Lee, S. Li and G. Barbastathis: “Lensless computational imaging through deep learning”, *Optica*, **4**, 9, pp. 1117–1125 (2017).
- [29] S. W. Paine and J. R. Fienup: “Machine learning for improved image-based wavefront sensing”, *Optics Letters*, **43**, 6, pp. 1235–1238 (2018).
- [30] H. Guo, Y. Xu, Q. Li, S. Du, D. He, Q. Wang and Y. Huang: “Improved Machine

- Learning Approach for Wavefront Sensing”, *Sensors*, **19**, 3533, pp. 1–13 (2019).
- [31] R. Horisaki, R. Takagi and J. Tanida: “Deep-learning-generated holography”, *Appl. Opt.*, **57**, 14, pp. 3859–3863 (2018).
- [32] Y. Rivenson, Z. Göröcs, H. Günaydin, Y. Zhang, H. Wang and A. Ozcan: “Deep learning microscopy”, *Optica*, **4**, 11, pp. 1437–1443 (2017).
- [33] Y. J. Jo, S. Park, J. H. Jung, J. Yoon, H. Joo, M. H. Kim, S. J. Kang, M. C. Choi, S. Y. Lee and Y. K. Park: “Holographic deep learning for rapid optical screening of anthrax spores”, *Science Advances*, **3**, 8, pp. 1–9 (2017).
- [34] S. Ota, R. Horisaki, Y. Kawamura, M. Ugawa, I. Sato, K. Hashimoto, R. Kamesawa, K. Setoyama, S. Yamaguchi, K. Fujiu, K. Waki and H. Noji: “Ghost cytometry”, *Science*, **360**, 6394, pp. 1246–1251 (2018).
- [35] J. W. Goodman: “Introduction to Fourier optics”, McGraw-Hill (1996).
- [36] E. CuChe, F. Bevilacqua and C. Depeursinge: “Digital holography for quantitative phase-contrast imaging.”, *Optics letters*, **24**, 5, pp. 291–293 (1999).
- [37] C. J. Mann, L. Yu, C.-M. Lo and M. K. Kim: “High-resolution quantitative phase-contrast microscopy by digital holography”, *Optics Express*, **13**, 22, pp. 8693–8698 (2005).
- [38] P. Xia, Y. ShimozaTo, Y. Ito, T. Tahara, T. Kakue, Y. Awatsuji, K. Nishio, S. Ura, T. Kubota and O. Matoba: “Improvement of color reproduction in color digital holography by using spectral estimation technique”, *Applied Optics*, **50**, 34, pp. 177–182 (2011).
- [39] E. Shaffer, C. Moratal, P. Magistretti, P. Marquet and C. Depeursinge: “Label-free second-harmonic phase imaging of biological specimen by digital holographic microscopy”, *Optics Letters*, **35**, 24, pp. 4102–4194 (2010).
- [40] N. T. Shaked: “Quantitative phase microscopy of biological samples using a portable interferometer”, *Optics Letters*, **37**, 11, pp. 2016–2018 (2012).
- [41] A. V. Belashov, A. A. Zhikhoreva, T. N. Belyaeva, E. S. Kornilova, N. V. Petrov, A. V. Salova, I. V. Semenova and O. S. Vasyutinskii: “Digital holographic microscopy in label-free analysis of cultured cells’ response to photodynamic treatment”, *Optics Letters*, **41**, 21, pp. 5035–5038 (2016).
- [42] V. Srinivasan, H. C. Liu and M. Halioua: “Automated phase-measuring profilometry

- of 3-D diffuse objects”, *Applied Optics*, **23**, 18, pp. 3105–3108 (1984).
- [43] R. J. Hull and L. C. Bradley: “Measurement of absorption-line profiles with a Fabry-Perot interferometer”, *Journal of the Optical Society of America*, **57**, 1, pp. 11–18 (1967).
- [44] T. Kwon and S.-W. Kim: “Fiber-optic interferometer for surface profile measurement with vibration suppression”, *Optics Express*, **19**, 5, pp. 4223–4230 (2011).
- [45] M. H. Maleki and A. J. Devaney: “Phase-retrieval and intensity-only reconstruction algorithms for optical diffraction tomography”, *J. Opt. Soc. Am. A*, **10**, 5, pp. 1086–1092 (1993).
- [46] S. Marathe, S. S. Kim, S. N. Kim, C. Kim, H. C. Kang, P. V. Nickles and D. Y. Noh: “Coherent diffraction surface imaging in reflection geometry”, *Optics Express*, **18**, 7, pp. 7253–7262 (2010).
- [47] A. Burvall, U. Lundström, P. A. C. Takman, D. H. Larsson and H. M. Hertz: “Phase retrieval in x-ray phase-contrast imaging suitable for tomography”, *Optics Express*, **19**, 11, pp. 10359–10376 (2011).
- [48] T. Latychevskaia, J.-N. Longchamp and H.-W. Fink: “When holography meets coherent diffraction imaging”, *Optics Express*, **20**, 27, pp. 28871–28892 (2012).
- [49] D. Sayre: “Some implications of a theorem due to Shannon”, *Acta Crystallographica*, **5**, 6, p. 843 (1952).
- [50] D. L. Misell: “An examination of an iterative method for the solution of the phase problem in optics and electron optics: II. sources of error”, *Journal of Physics D: Applied Physics*, **6**, 18, pp. 2200–2216 (1973).
- [51] J. R. Fienup: “Reconstruction of an object from the modulus of its Fourier transform.”, *Optics letters*, **3**, 1, pp. 27–29 (1978).
- [52] J. R. Fienup: “Phase retrieval algorithms: a comparison”, *Appl. Opt.*, **21**, 15, pp. 2758–2769 (1982).
- [53] J. R. Fienup and C. C. Wackerman: “Phase-retrieval stagnation problems and solutions”, *Journal of the Optical Society of America A*, **3**, 11, pp. 1897–1907 (1986).
- [54] R. P. Millane: “Phase retrieval in crystallography and optics”, *J. Opt. Soc. Am. A*, **7**, 3, pp. 394–411 (1990).
- [55] J. Miao, D. Sayre and H. N. Chapman: “Phase retrieval from the magnitude of

- the Fourier transforms of nonperiodic objects”, *Journal of the Optical Society of America A*, **15**, 6, pp. 1662–1669 (1998).
- [56] J. Miao, P. Charalambous, J. Kirz and D. Sayre: “Extending the methodology of x-ray crystallography to allow imaging of micrometre-sized non-crystalline specimens”, *Nature*, **400**, 6742, pp. 342–344 (1999).
- [57] V. Katkovnik, I. Shevkunov, N. V. Petrov and K. Egiazarian: “Computational super-resolution phase retrieval from multiple phase-coded diffraction patterns: simulation study and experiments”, *Optica*, **4**, 7, pp. 786–794 (2017).
- [58] I. Shevkunov, V. Katkovnik, N. V. Petrov and K. Egiazarian: “Super-resolution microscopy for biological specimens: lensless phase retrieval in noisy conditions”, *Biomedical Optics Express*, **9**, 11, pp. 5511–5523 (2018).
- [59] J. Bertolotti, E. G. Van Putten, C. Blum, A. Lagendijk, W. L. Vos and A. P. Mosk: “Non-invasive imaging through opaque scattering layers”, *Nature*, **491**, 11, pp. 232–234 (2012).
- [60] O. Katz, P. Heidmann, M. Fink and S. Gigan: “Non-invasive single-shot imaging through scattering layers and around corners via speckle correlations”, *Nature Photonics*, **8**, 10, pp. 784–790 (2014).
- [61] Y. Okamoto, R. Horisaki and J. Tanida: “Noninvasive three-dimensional imaging through scattering media by three-dimensional speckle correlation”, *Optics Letters*, **44**, 10, pp. 2526–2529 (2019).
- [62] R. Horisaki, Y. Okamoto and J. Tanida: “Single-shot noninvasive three-dimensional imaging through scattering media”, *Optics Letters*, **44**, 16, pp. 4032–4035 (2019).
- [63] R. A. Gonsalves: “Phase retrieval and diversity In adaptive optics”, *Optical Engineering*, **21**, 5, pp. 19–22 (1982).
- [64] F. Roddier: “Curvature sensing and compensation: a new concept in adaptive optics”, *Applied Optics*, **27**, 7, pp. 1223–1225 (1988).
- [65] R. Ragazzoni: “Pupil plane wavefront sensing with an oscillating prism”, *Journal of Modern Optics*, **43**, 2, pp. 289–293 (1996).
- [66] B. C. Platt and R. Shack: “History and principles of Shack-Hartmann wavefront sensing”, *Journal of Refractive Surgery*, **17**, October 2001, pp. 573–577 (2001).
- [67] M. Shaw, K. O’Holleran and C. Paterson: “Investigation of the confocal wavefront

- sensor and its application to biological microscopy”, *Optics Express*, **21**, 16, pp. 19353–19362 (2013).
- [68] C. Wu, J. Ko and C. C. Davis: “Determining the phase and amplitude distortion of a wavefront using a plenoptic sensor”, *Journal of the Optical Society of America A*, **32**, 5, pp. 964–978 (2015).
- [69] L. Zhu, P. Sun and F. Yeshaiahu: “Adaptive control of a micromachined continuous membrane deformable mirror for aberration compensation”, *Shiyou Daxue Xuebao/Journal of the University of Petroleum China*, **22**, 6, pp. 1–8 (1998).
- [70] Y. Iino and P. Davis: “Switching of self-organized patterns in mutually modulating liquid crystal devices for beam control”, *Journal of Applied Physics*, **85**, 7, pp. 3399–3405 (1999).
- [71] F. Yara, H. Kang and L. Onural: “State of the art in holographic displays: a survey”, *IEEE/OSA Journal of Display Technology*, **6**, 10, pp. 443–454 (2010).
- [72] V. Toporovskiy, A. Kudryashov, V. Samarkin, J. Sheldakova, A. Rukosuev, A. Skvortsov and D. Pshonkin: “Bimorph deformable mirror with a high density of electrodes to correct for atmospheric distortions”, *Applied Optics*, **58**, 22, pp. 6019–6026 (2019).
- [73] E. J. Fernández and P. Artal: “Membrane deformable mirror for adaptive optics: performance limits in visual optics”, *Optics Express*, **11**, 9, pp. 1056–1069 (2003).
- [74] H. Wang: “Research on a bimorph piezoelectric deformable mirror for adaptive optics in optical telescope”, *Optics Express*, **25**, 7, pp. 8115–8122 (2017).
- [75] H. Takagi, K. Nakamura, T. Goto, P. B. Lim and M. Inoue: “Magneto-optic spatial light modulator with submicron-size magnetic pixels for wide-viewing-angle holographic displays”, *Optics Letters*, **39**, 11, pp. 3344–3347 (2014).
- [76] S. Borgsmüller, S. Noehte, C. Dietrich, T. Kresse and R. Männer: “Computer-generated stratified diffractive optical elements”, *Applied Optics*, **42**, 26, pp. 5274–5283 (2003).
- [77] H. Wang and R. Piestun: “Dynamic 2D implementation of 3D diffractive optics”, *Optica*, **5**, 10, pp. 1220–1228 (2018).
- [78] M. Zheng, Y. Ogura and J. Tanida: “Three-dimensional dynamic optical manipulation by combining a diffractive optical element and a spatial light modulator”,

- Optical Review, **15**, 2, pp. 105–109 (2008).
- [79] A. Shibukawa, A. Okamoto, M. Takabayashi and A. Tomita: “Spatial cross modulation method using a random diffuser and phase-only spatial light modulator for constructing arbitrary complex fields”, *Optics Express*, **22**, 4, pp. 3968–3982 (2014).
- [80] J. Park, K. R. Lee and Y. K. Park: “Ultrathin wide-angle large-area digital 3D holographic display using a non-periodic photon sieve”, *Nature Communications*, **10**, 1304, pp. 1–8 (2019).
- [81] W. Song, Q. Cheng, P. Surman, Y. Liu, Y. Zheng, Z. Lin and Y. Wang: “Design of a light-field near-eye display using random pinholes”, *Optics Express*, **27**, 17, pp. 23763–23774 (2019).
- [82] H. Yu, K. Lee, J. Park and Y. Park: “Ultrahigh-definition dynamic 3D holographic display by active control of volume speckle fields”, *Nature Photonics*, **11**, 3, pp. 186–192 (2017).
- [83] X. Lin, Y. Rivenson, N. T. Yardimci, M. Veli, Y. Luo, M. Jarrahi and A. Ozcan: “All-optical machine learning using diffractive deep neural networks.”, *Science*, **361**, 6406, pp. 1004–1008 (2018).
- [84] G. Barbastathis, A. Ozcan and G. Situ: “On the use of deep learning for computational imaging”, *Optica*, **6**, 8, pp. 921–943 (2019).
- [85] C. Dong, C. C. Loy, K. He and X. Tang: “Learning a deep convolutional network for image super-resolution”, *Computer Vision – ECCV 2014* (Eds. by D. Fleet, T. Pajdla, B. Schiele and T. Tuytelaars), Cham, Springer International Publishing, pp. 184–199 (2014).
- [86] C. Dong, C. C. Loy, K. He and X. Tang: “Image Super-Resolution Using Deep Convolutional Networks”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 2, pp. 295–307 (2016).
- [87] M. Mardani, H. Monajemi, V. Pappas, S. Vasanawala, D. Donoho and J. Pauly: “Recurrent generative adversarial networks for proximal learning and automated compressive image recovery”, arXiv preprint, p. 1711.10046 (2017).
- [88] C. J. Schuler, H. C. Burger, S. Harmeling and B. Scholkopf: “A machine learning approach for non-blind image deconvolution”, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 1067–1074

- (2013).
- [89] J. Sun, W. Cao, Z. Xu and J. Ponce: “Learning a convolutional neural network for non-uniform motion blur removal”, arXiv preprint, p. 1503.00593 (2015).
- [90] Y. Rivenson, Y. Zhang, H. Günaydn, D. Teng and A. Ozcan: “Phase recovery and holographic image reconstruction using deep learning in neural networks”, *Light: Science & Applications*, **7**, 17141, pp. 1–9 (2018).
- [91] T. Remez, O. Litany, R. Giryes and A. M. Bronstein: “Deep convolutional denoising of low-light images”, arXiv preprint, p. 1701.01687 (2017).
- [92] A. Goy, K. Arthur, S. Li and G. Barbastathis: “Low Photon Count Phase Retrieval Using Deep Learning”, *Physical Review Letters*, **121**, 24, pp. 1–5 (2018).
- [93] M. Lyu, W. Wang, H. Wang, H. Wang, G. Li, N. Chen and G. Situ: “Deep-learning-based ghost imaging”, *Scientific Reports*, **7**, 17865, pp. 1–6 (2017).
- [94] M. Lyu, H. Wang, G. Li and G. Situ: “Exploit imaging through opaque wall via deep learning”, arXiv preprint, p. 1708.07881 (2017).
- [95] P. Caramazza, A. Boccolini, D. Buschek, M. Hullin, C. F. Higham, R. Henderson, R. Murray-Smith and D. Faccio: “Neural network identification of people hidden from view with a single-pixel, single-photon detector”, *Scientific Reports*, **8**, 11945, pp. 1–6 (2018).
- [96] N. Ji: “Adaptive optical fluorescence microscopy”, *Nature Methods*, **14**, 4, pp. 374–380 (2017).
- [97] P. Schipani, L. Noethe, D. Magrin, K. Kuijken, C. Arcidiacono, J. Argomedo, M. Cappacioli, M. Dall’Ora, S. D’Orsi, J. Farinato, D. Fierro, R. Holzlöhner, L. Marty, C. Molfese, F. Perrotta, R. Ragazzoni, S. Savarese, A. Rakich and G. Umbriaco: “Active optics system of the VLT Survey Telescope”, *Applied Optics*, **55**, 7, pp. 1573–1583 (2016).
- [98] H. Campbell and A. Greenaway: “Wavefront sensing: from historical roots to the state-of-the-art”, *EAS Publ. Ser.*, **22**, pp. 165–185 (2006).
- [99] R. Horisaki, Y. Ogura, M. Aino and J. Tanida: “Single-shot phase imaging with a coded aperture”, *Optics Letters*, **39**, 22, pp. 6466–6469 (2014).
- [100] R. Horisaki, R. Egami and J. Tanida: “Single-shot phase imaging with randomized light (SPIRaL)”, *Optics Express*, **24**, 4, pp. 3765–3773 (2016).

- [101] C. Wang, X. Dun, Q. Fu and W. Heidrich: “Ultra-high resolution coded wavefront sensor”, *Optics Express*, **25**, 12, pp. 13736–13746 (2017).
- [102] P. Berto, H. Rigneault and M. Guillon: “Wavefront sensing with a thin diffuser”, *Optics Letters*, **42**, 24, pp. 5117–5120 (2017).
- [103] R. L. Kendrick, D. S. Acton and A. L. Duncan: “Phase-diversity wave-front sensor for imaging systems”, *Applied Optics*, **33**, 27, pp. 6533–6546 (1994).
- [104] H. Guo, N. Korablinova, Q. Ren and J. Bille: “Wavefront reconstruction with artificial neural networks”, *Optics Express*, **14**, 14, pp. 6456–6462 (2006).
- [105] F. Chollet: “Xception: deep learning with depthwise separable convolutions”, arXiv preprint, p. 1610.02357 (2017).
- [106] J. D. Schmidt: “Numerical simulation of optical wave propagation with examples in MATLAB”, SPIE, WA, USA, SPIE Bellingham, Washington, USA (2010).
- [107] A. Stern, Y. Zeltzer and Y. Rivenson: “Quantization error and dynamic range considerations for compressive imaging systems design”, *Journal of the Optical Society of America A*, **30**, 6, pp. 1069–1077 (2013).
- [108] L. G. Ellerbroek: “Shack-Hartmann wavefront sensing with elongated sodium laser beacons: centroiding versus matched filtering”, *Applied Optics*, **45**, 25, pp. 6568–6576 (2006).
- [109] D. P. Kingma and J. Ba: “Adam: a method for stochastic optimization”, arXiv preprint, p. 1412.6980 (2015).
- [110] G. Cohen, S. Afshar, J. Tapson and A. Van Schaik: “EMNIST: Extending MNIST to handwritten letters”, arXiv preprint, p. 1702.05373 (2017).
- [111] R. J. Noll: “Zernike polynomials and atmospheric turbulence.”, *J Opt Soc Am*, **66**, 3, pp. 207–211 (1976).
- [112] C. Metzler, P. Schniter, A. Veeraraghavan and R. baraniuk: “prDeep: robust phase retrieval with a flexible deep network”, arXiv preprint (Eds. by J. Dy and A. Krause), *Proceedings of Machine Learning Research*, Stockholmsmässan, Stockholm Sweden, PMLR, p. 1803.00212 (2018).
- [113] Ç. Isil, F. S. Oktem and A. Koç: “Deep iterative reconstruction for phase retrieval”, *CoRR* (2019).
- [114] M. J. Cherukara, Y. S. Nashed and R. J. Harder: “Real-time coherent diffraction

- inversion using deep generative networks”, *Scientific Reports*, **8**, 16520, pp. 1–8 (2018).
- [115] R. Horisaki, R. Takagi and J. Tanida: “Learning-based focusing through scattering media”, *Applied Optics*, **56**, 15, pp. 4358–4362 (2017).
- [116] Y. Nishizaki, M. Valdivia, R. Horisaki, K. Kitaguchi, M. Saito, J. Tanida and E. Vera: “Deep learning wavefront sensing”, *Optics Express*, **27**, 1, pp. 240–251 (2019).
- [117] J. White and Z. Chang: “Attosecond streaking phase retrieval with neural network”, *Optics Express*, **27**, 4, pp. 4799–4807 (2019).
- [118] X. Yuan and Y. Pu: “Parallel lensless compressive imaging via deep convolutional neural networks”, *Optics Express*, **26**, 2, pp. 1962–1977 (2018).
- [119] U. Kürüm, P. R. Wiecha, R. French and O. L. Muskens: “Deep learning enabled real time speckle recognition and hyperspectral imaging using a multimode fiber array”, *Optics Express*, **27**, 15, pp. 20965–20979 (2019).
- [120] S. Van der Jeught and J. J. J. Dirckx: “Deep neural networks for single shot structured light profilometry”, *Optics Express*, **27**, 12, pp. 17091–17101 (2019).
- [121] T. Shimobaba, T. Takahashi, Y. Yamamoto, Y. Endo, A. Shiraki, T. Nishitsuji, N. Hoshikawa, T. Kakue and T. Ito: “Digital holographic particle volume reconstruction using a deep neural network”, *Applied Optics*, **58**, 8, pp. 1900–1906 (2019).
- [122] K. He, X. Zhang, S. Ren and J. Sun: “Deep residual learning for image recognition”, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778 (2016).
- [123] S. Ioffe and C. Szegedy: “Batch normalization: accelerating deep network training by reducing internal covariate shift”, *Proceedings of the 32nd International Conference on Machine Learning (ICML’15) (JMLR, 2015)* (Eds. by F. B. Blei and David), Vol. 37, PMLR, pp. 448–456 (2015).
- [124] V. Nair and G. E. Hinton: “Rectified linear units improve restricted boltzmann machines”, *Proceedings of the 27th International Conference on International Conference on Machine Learning, ICML’10, USA, Omnipress*, pp. 807–814 (2010).
- [125] J. R. Fienup: “Invariant error metrics for image reconstruction”, *Applied Optics*, **36**, 32, pp. 8352–8357 (1997).

- [126] A. Peternier, J. P. Merryman Boncori and P. Pasquali: “Near-real-time focusing of ENVISAT ASAR Stripmap and Sentinel-1 TOPS imagery exploiting OpenCL GPGPU technology”, *Remote Sensing of Environment*, **202**, 12, pp. 45–53 (2017).
- [127] G. Nehmetallah and P. P. Banerjee: “Applications of digital and analog holography in three-dimensional imaging”, *Advances in Optics and Photonics*, **4**, 4, pp. 472–553 (2012).
- [128] F. Yara, H. Kang and L. Onural: “Circular holographic video display system”, *Optics Express*, **19**, 10, pp. 9147–9156 (2011).
- [129] Y. Sando, M. Itoh and T. Yatagai: “Color computer-generated holograms from projection images”, *Optics Express*, **12**, 11, pp. 2487–2493 (2004).
- [130] Y. Hayasaki, M. Itoh, T. Yatagai and N. Nishida: “Nonmechanical optical manipulation of microparticle using spatial light modulator”, *Optical Review*, **6**, 1, pp. 24–27 (1999).
- [131] J. E. Curtis, B. A. Koss and D. G. Grier: “Dynamic holographic optical tweezers”, *Optics Communications*, **207**, 1-6, pp. 169–175 (2002).
- [132] E. Eriksson, S. Keen, J. Leach, M. Goksör and M. J. Padgett: “The effect of external forces on discrete motion within holographic optical tweezers”, *Optics Express*, **15**, 26, pp. 18268–18274 (2007).
- [133] S. Zwick, C. Schaub, T. Haist and W. Osten: “Light fields with an axially expanded intensity distribution for stable three-dimensional optical trapping”, *Optics Express*, **18**, 19, pp. 19941–19950 (2010).
- [134] Y. Ogura, Y. Kazayama, T. Nishimura and J. Tanida: “Large-area manipulation of microdroplets by holographic optical tweezers based on a hybrid diffractive system”, *Applied Optics*, **50**, 34, pp. 1–5 (2011).
- [135] M. L. Huebschman, B. Munjuluri and H. R. Garner: “Dynamic holographic 3-D image projection”, *Optics Express*, **11**, 5, pp. 437–445 (2003).
- [136] X. Quan, M. Kumar, O. Matoba, Y. Awatsuji, Y. Hayasaki, S. Hasegawa and H. Wake: “Three-dimensional stimulation and imaging-based functional optical microscopy of biological cells”, *Optics Letters*, **43**, 21, pp. 5447–5450 (2018).
- [137] A. J. Caley, M. J. Thomson, J. Liu, A. J. Waddie and M. R. Taghizadeh: “Diffractive optical elements for high gain lasers with arbitrary output beam profiles”, *Optics*

- Express, **15**, 17, pp. 10699–10704 (2007).
- [138] J. Liu and M. R. Taghizadeh: “Improved algorithm for the design of diffractive phase elements for beam shaping”, Conference on Lasers and Electro-Optics Europe - Technical Digest, **27**, 16, pp. 1463–1465 (2003).
- [139] L. Golan, I. Reutsky, N. Farah and S. Shoham: “Design and characteristics of holographic neural photo-stimulation systems”, Journal of Neural Engineering, **6**, 6, pp. 1–14 (2009).
- [140] V. Nikolenko, B. O. Watson, R. Araya, A. Woodruff, D. S. Peterka and R. Yuste: “SLM microscopy: scanless two-photon imaging and photostimulation with spatial light modulators”, Frontiers in Neural Circuits, **2**, 5, pp. 1–14 (2008).
- [141] H. Yu, J. Jang, J. Lim, J.-H. Park, W. Jang, J.-Y. Kim and Y. Park: “Depth-enhanced 2-D optical coherence tomography using complex wavefront shaping”, Optics Express, **22**, 7, pp. 7514–7523 (2014).
- [142] R. Horisaki, R. Takagi and J. Tanida: “Learning-based single-shot superresolution in diffractive imaging”, Applied Optics, **56**, 32, pp. 8896–8901 (2017).
- [143] R. W. Gerchberg: “A practical algorithm for the determination of phase from image and diffraction plane pictures”, Optik, **35**, 2, pp. 1–6 (1972).
- [144] A. Maiden, D. Johnson and P. Li: “Further improvements to the ptychographical iterative engine”, Optica, **4**, 7, pp. 736–745 (2017).